

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

ÇOK SEVİYELİ GÖRÜNTÜ EŞİKLEME PROBLEMİ İÇİN META
SEZGİSEL OPTİMİZASYON ALGORİTMASI TASARIMI

YÜKSEK LİSANS TEZİ

Samoua ALSAMOUA

HAZİRAN 2025

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAZILIM MÜHENDİSLİĞİ ANABİLİM DALI

**ÇOK SEVİYELİ GÖRÜNTÜ EŞİKLEME PROBLEMİ İÇİN META
SEZGİSEL OPTİMİZASYON ALGORİTMASI TASARIMI**

Samoua ALSAMOUA

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"YÜKSEK LİSANS (YAZILIM MUHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 05 / 05 / 2025

Tezin Savunma Tarihi : 11 / 06 / 2025

Tez Danışmanı : Dr. Öğr. Üyesi Asuman GÜNAY YILMAZ

Trabzon 2025

ÖNSÖZ

“Çok Seviyeli Görüntü Eşikleme Problemi İçin Meta-Sezgisel Optimizasyon Algoritması Tasarımı” isimli bu tez çalışması, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Yazılım Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS programı kapsamında hazırlanmıştır.

Tez sürecinde bilgi, rehberlik ve sabırları ile bana yol gösteren danışman hocam Dr. Öğr. Üyesi Asuman GÜNAY YILMAZ’a en içten teşekkürlerimi sunarım. Ayrıca, yapıcı eleştirileri ve önerileriyle çalışmama katkıda bulunan Sayın Prof. Dr. Hamdi Tolga KAHRAMAN ve Sayın Dr. Öğr. Üyesi M. Hakan BOZKURT’a şükranlarımı ifade ederim.

Yolculuğum boyunca yanımda olan araştırma ortaklarıma, arkadaşlarıma ve bölümümüzün değerli akademik kadrosuna teşekkür ederim. Bu süreçte aldığım destekler ve paylaşılan deneyimler, çalışmanın tamamlanmasında önemli bir rol oynamıştır.

Eğitim-öğretim hayatımda bilgi ve deneyimlerini paylaşarak beni geliştiren tüm hocalarıma, asistan arkadaşlarıma ve aileme minnettarlığımı sunarım. Annem Esma Hanım ve rahmetli babam Mofeed Bey’in sevgisi ve fedakarlıkları sayesinde bugünlere gelebildim. Hayatımın her anında yanımda olan kardeşlerim Ahmed Mahmod ve Yaman Kadri’ye de sonsuz teşekkürlerimi ifade ederim.

Bu tezin, gelecekteki çalışmalara katkı sağlaması dileğiyle.

Samoua ALSAMOUA

Trabzon 2025

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Çok Seviyeli Görüntü Eşikleme Problemi İçin Meta-Sezgisel Optimizasyon Algoritması Tasarımı” başlıklı bu çalışmayı, baştan sona kadar danışmanım Dr. Öğr. Üyesi Asuman GÜNAY YILMAZ’ın rehberliğinde tamamladığımı, verileri/örnekleri kendim topladığımı veya kaynaklarını şeffaf bir şekilde belirttiğimi, deneyleri/analizleri ilgili ortamlarda gerçekleştirdiğimi/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 11 /06/2025

Samoua ALSAMOUA

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	VI
TEZ ETİK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
ÖZET	XI
SUMMARY.....	XII
ŞEKİLLER DİZİNİ	XIII
TABLolar DİZİNİ.....	XIV
SEMBOLLER VE KISALTMALAR DİZİNİ	XVI
1. GENEL BİLGİLER	1
1.1. Görüntü Segmentasyonu Genel Bakış	1
1.2. Görüntü Segmentasyonundaki Zorluklar	1
1.3. Çok Seviyeli Görüntü Segmentasyonunda Meta Segisel Algoritmaların Kullanımı.....	2
1.4. Görüntü Segmentasyonu Uygulamaları	3
1.5. Meta-sezgisel Arama Algoritmalarına Giriş	5
1.6. Araştırmanın Amaçları ve Katkıları	6
1.7. Literatür Özeti	8
2. YAPILAN ÇALIŞMALAR.....	15
2.1. Çok Seviyeli Eşikleme Probleminin Tanımı	15
2.1.1. Kapur Entropisi Tabanlı Eşikleme	16
2.1.2. Sınıf-arası Varyans Tabanlı Eşikleme (Otsu Yöntemi)	17
2.2. Meta-sezgisel Arama Algoritmaları (MSA)	19
2.2.1. Yapay Arı Kolonisi (ABC) Algoritması	19
2.2.2. Guguk Kuşu Arama (CS) Algoritması	20
2.2.3. Diferansiyel Evrim (DE) Algoritması	21
2.2.4. Gri Kurt Optimizasyon (GWO) Algoritması	22
2.2.5. Harris Şahinler Optimizasyonu (HHO) Algoritması.....	23
2.2.6. Güve-Alev Optimizasyonu (MFO) Algoritması	24
2.2.7. Parçacık Sürü Optimizasyonu (PSO) Algoritması	26
2.2.8. Sinüs Kosinüs Algoritması (SCA)	27
2.2.9. Simbiyotik Organizmalar Arama (SOS) Algoritması	28

2.2.10. Salp Sürüsü Algoritması (SSA)	29
2.2.11. Balina Optimizasyon Algoritması (WOA)	30
2.3. Önerilen Çok Aşamalı Hibrit Algoritmalar	31
2.3.1. Hibrit Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu Algoritması (MFO-PSO).....	32
2.3.2. Hibrit Güve-Alev Optimizasyonu-Salp Sürüsü Algoritması (MFO-SSA).....	34
2.3.3. Hibrit Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu-Salp Sürüsü Algoritması (MFO-PSO-SSA).....	36
2.4. Önerilen Ağırlıklı Şempanze Optimizasyon Algoritması ile Uygunluk-Mesafe Dengesi (WChOA-UMD).....	39
2.4.1. Ağırlıklı Şempanze Optimizasyon Algoritması (WChOA)	40
2.4.2. Uygunluk-Mesafe Dengesi (UMD)	43
2.4.3. Ağırlıklı Şempanze Optimizasyon Algoritması ile Uygunluk-Mesafe Dengesi (WChOA-UMD)	44
2.4.4. Hesaplama Karmaşıklığı	48
3. BULGULAR VE TARTIŞMA	50
3.1. Deneysel Ayarlar	50
3.2. Önerilen Çok Aşamalı Hibrit Algoritmaların Deneysel Bulguları.....	51
3.2.1. Veri Seti	51
3.2.2. MSA'lar İçin İstatistiksel Analiz	52
3.2.3. Önerilen Çok Aşamalı Hibrit Algoritmaların Performans Değerlendirmesi	54
3.2.4. Görüntü Segmentasyonu Performans Metrikleri	55
3.3. Önerilen WChOA-UMD Algoritmasının Deneysel Bulguları	64
3.3.1. Önerilen WChOA-UMD Algoritmasının Performansını Test Etme ve Analiz Etme	64
3.3.2. Friedman ve Wilcoxon Testleri ile Algoritmaların Performanslarının İstatistiksel Analizi.....	65
3.3.3. Önerilen WChOA-UMD Yönteminin Görüntü Segmentasyonu Performansı	68
3.3.4. İstatistiksel Analiz.....	70
3.3.5. Amaç Fonksiyonu Değeri ile Performans Değerlendirme	72
3.3.6. PSNR, SSIM ve FSIM Kullanılarak Performans Değerlendirme	73
4. SONUÇLAR.....	81
5. ÖNERİLER.....	83
6. KAYNAKLAR	84

7. EKLER.....	89
ÖZGEÇMİŞ	



Yüksek Lisans Tezi

ÖZET

ÇOK SEVİYELİ GÖRÜNTÜ EŞİKLEME PROBLEMİ İÇİN META SEZGİSEL OPTİMİZASYON ALGORİTMASI TASARIMI

Samoua ALSAMOUA

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Yazılım Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Asuman GÜNAY YILMAZ
2025, 123 Sayfa

Çok seviyeli görüntü segmentasyonu, görüntülerin anlamlı bölgelere ayrılarak analiz edilmesini sağlayan temel bir tekniktir. Ancak mevcut yöntemler genellikle yüksek hesaplama maliyeti, gürültüye duyarlılık ve çeşitli veri kümeleriyle başa çıkmada yetersizlik gibi sorunlarla karşı karşıyadır. Bu tezde, çok seviyeli görüntü segmentasyonu için özel olarak tasarlanmış iki yeni yaklaşım sunulmaktadır: Uygunluk-Mesafe Dengesi mekanizmasıyla Ağırlıklı Şempanze Optimizasyon Algoritması (WChOA-UMD) ve Güve-Alev Optimizasyonu (MFO), Parçacık Sürü Optimizasyonu (PSO) ve Salp Sürüsü Algoritması (SSA) kullanarak geliştirilen çok aşamalı hibrit algoritmalar (MFO-PSO, MFO-SSA ve MFO-PSO-SSA). Önerilen algoritmalar, çözüm uzayında keşif ve sömürü süreçlerini dengeli bir şekilde yöneterek yakınsama hızını ve segmentasyonu doğruluğunu artırmaktadır. Önerilen yöntemlerin etkinliğini değerlendirmek için Kapur entropisi ve Otsu yöntemi amaç fonksiyonları kullanılarak, 11 yaygın meta sezgisel algoritmayla karşılaştırma yapılmıştır. Deneyler, WChOA-UMD algoritması için $m = 2, 4, 6, 8, 10$ ve 12 eşik seviyeleri ve 10 görüntü üzerinde, hibrit algoritmalar için ise $m = 2, 4, 6$ ve 8 eşik seviyeleri ve 100 görüntü üzerinde gerçekleştirilmiştir. Değerlendirme metrikleri olarak PSNR, SSIM ve FSIM kullanılmıştır. Friedman ve Wilcoxon testlerine dayalı istatistiksel analizler, önerilen yöntemlerin segmentasyon başarısını doğrulamaktadır.

Anahtar Kelimeler: Meta-Sezgisel Arama Algoritmaları, Uygunluk-Mesafe Dengesi, Çok Seviyeli Eşikleme, Görüntü Segmentasyonu

MSc. Thesis

SUMMARY

METAHEURISTIC OPTIMIZATION ALGORITHM DESIGN FOR MULTILEVEL IMAGE THRESHOLDING PROBLEM

Samoua ALSAMOUA

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Software Engineering Graduate Program
Supervisor: Assoc. Prof. Asuman Günay YILMAZ
2025, 123 Pages

Multilevel image segmentation is essential for dividing images into meaningful regions for analysis. However, existing methods often suffer from high computational cost, noise sensitivity, and limitations with diverse datasets. This thesis proposes two novel solutions: the Weighted Chimp Optimization Algorithm with Fitness-Distance Balance (WChOA-FDB) and a set of multi-stage hybrid algorithms (MFO-PSO, MFO-SSA, and MFO-PSO-SSA) developed by combining Moth-Flame Optimization (MFO), Particle Swarm Optimization (PSO), and Salp Swarm Algorithm (SSA). These novel algorithms enhance convergence speed and segmentation accuracy by effectively balancing exploration and exploitation. To evaluate their effectiveness, the proposed methods are compared with 11 well-known metaheuristic algorithms: (ABC, CS, DE, GWO, HHO, MFO, PSO, SCA, SOS, SSA, and WOA), using Kapur's entropy and Otsu's method as objective functions. Experiments were conducted on 10 images for WChOA-FDB at threshold levels $m = 2, 4, 6, 8, 10$ and 12 , and on 100 images for the hybrid algorithms at $m = 2, 4, 6$, and 8 . Evaluation metrics include PSNR, SSIM, and FSIM. Statistical analyses using the Friedman and Wilcoxon tests confirm the superiority of the proposed methods. This thesis offers significant contributions to the field of metaheuristic-based image segmentation.

Key Words: Metaheuristic Search Algorithms, Fitness-Distance Balance, Multilevel Thresholding, Image Segmentation.

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Çok aşamalı hibrit MFO-PSO algoritmasının akış şeması.....	33
Şekil 2. Çok aşamalı hibrit MFO-SSA algoritmasının akış şeması.....	35
Şekil 3. Çok aşamalı hibrit MFO-PSO-SSA algoritmasının akış şeması	37
Şekil 4. Berkeley veri setinden örnek görüntüler ve histogramları (soldan sağa: '102061.jpg', '208001.jpg', '55073.jpg', '126007.jpg', '299086.jpg', '86068.jpg')	52
Şekil 5. Örnek görüntüler için kutu grafikleri (Kapur entropisi, $m=8$)	62
Şekil 6. Örnek görüntüler için kutu grafikleri (Otsu yöntemi, $m=8$).....	62
Şekil 7. MFO-PSO-SSA ile segmente edilmiş görüntüler (Kapur entropisi).....	63
Şekil 8. MFO-SSA ile segmente edilmiş görüntüler (Otsu yöntemi).....	64
Şekil 9. Test görüntüleri ve histogramları (soldan sağa: 12003.jpg, 108073.jpg, 124084.jpg, 232038.jpg, 323016.jpg, 106024.jpg, 291000.jpg, 12084.jpg, 61060.jpg, 65010.jpg)	69
Şekil 10. Ortalama PSNR değerleri (Otsu 500: $maxFEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $maxFEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $maxFEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $maxFEs = 1000 \times m$ için Kapur entropisi).....	74
Şekil 11. Ortalama SSIM değerleri (Otsu 500: $maxFEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $maxFEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $maxFEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $maxFEs = 1000 \times m$ için Kapur entropisi).....	75
Şekil 12. Ortalama FSIM değerleri (Otsu 500: $maxFEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $maxFEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $maxFEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $maxFEs = 1000 \times m$ için Kapur entropisi).....	76
Şekil 13. Otsu yöntemi ve $maxFEs = 500 \times m$ için segmentasyon sonuçları.....	77
Şekil 14. Otsu yöntemi ve $maxFEs = 1000 \times m$ için segmentasyon sonuçları.....	78
Şekil 15. Kapur entropisi ve $maxFEs = 500 \times m$ için segmentasyon sonuçları	79
Şekil 16. Kapur entropisi ve $maxFEs = 1000 \times m$ için segmentasyon sonuçları	80

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Doğadan ilham alan algoritmaların genel sınıflandırması	7
Tablo 2. WChOA- UMD varyantlarının matematiksel modeli	46
Tablo 3. MSA ayarları	51
Tablo 4. MSA'lar için friedman puanları ve sıralamaları	53
Tablo 5. Tüm eşik seviyelerinde MSA'ların ortalama Friedman puanları ve sıralamaları	54
Tablo 6. Önerilen algoritmaların Friedman sıralamaları ve puanları	55
Tablo 7. Önerilen çok aşamalı hibrit algoritmaların kapur entropisi için ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri	57
Tablo 8. Önerilen çok aşamalı hibrit algoritmaların otsu yöntemi için ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri)	58
Tablo 9. Veri setindeki örnek görüntüler için kapur entropisi amaç fonksiyonu kullanılarak elde edilen amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri	59
Tablo 10. Veri setindeki örnek görüntüler için otsu yöntemi amaç fonksiyonu kullanılarak elde edilen amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri	60
Tablo 11. CEC'2020 test paketi özeti.....	65
Tablo 12. WChOA ve WChOA-UMD varyantları için friedman testi sıralamaları.....	66
Tablo 13. WChOA ve WChOA-UMD varyantları için Wilcoxon ikili karşılaştırma sonuçları	67
Tablo 14. Algoritma ayarları	70
Tablo 15. Algoritmaların farklı eşik seviyelerinde Friedman sıralamaları (Otsu yöntemi)	71
Tablo 16. Algoritmaların farklı eşik seviyelerinde Friedman sıralamaları (Kapur entropisi)	72
Tablo 17. En iyi Friedman puanlarına sahip algoritmalar	76

Ek Tablo 1. Otsu yöntemi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=500 \times m$)	89
Ek Tablo 2. Otsu yöntemi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=1000 \times m$)	91
Ek Tablo 3. Kapur entropisi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=500 \times m$)	93
Ek Tablo 4. Kapur entropisi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=1000 \times m$)	95
Ek Tablo 5. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların PSNR sonuçları	97
Ek Tablo 6. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların PSNR sonuçları	100
Ek Tablo 7. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların PSNR sonuçları	102
Ek Tablo 8. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların PSNR sonuçları	104
Ek Tablo 9. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların SSIM sonuçları	106
Ek Tablo 10. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların SSIM sonuçları	109
Ek Tablo 11. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların SSIM sonuçları	111
Ek Tablo 12. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların SSIM sonuçları	113
Ek Tablo 13. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların FSIM sonuçları	115
Ek Tablo 14. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların FSIM sonuçları	118
Ek Tablo 15. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların FSIM sonuçları	120
Ek Tablo 16. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların FSIM sonuçları	122

SEMBOLLER VE KISALTMALAR DİZİNİ

UMD	: Uygunluk-Mesafe Dengesi
MSA	: Meta-sezgisel Arama Algoritmaları
DİA	: Doğadan İlham Alan Algoritmalar
WChOA	: Ağırlıklı Şempanze Optimizasyon Algoritması
ABC	:Yapay Arı Kolonisi Algoritması
CS	: Guguk Kuşu Arama Algoritması
DE	: Diferansiyel Evrim Algoritması
GWO	: Gri Kurt Optimizasyonu Algoritması
HHO	: Harris Şahini Optimizasyonu Algoritması
MFO	: Güve-Alev Optimizasyonu Algoritması
PSO	: Parçacık Sürüşü Optimizasyonu Algoritması
SSA	: Salp Sürü Algoritması
SCA	: Sinüs-Kosinüs Algoritması
SOS	: Simbiyotik Organizmalar Arama Algoritması
WOA	: Balina Optimizasyon Algoritması
PSNR	: Zirve Sinyal-Gürültü Oranı
SSIM	: Yapısal Benzerlik İndeksi
FSIM	: Özellik Benzerlik İndeksi
MSE	: Ortalama Kare Hata
H_n	: n. bölge entropisi
σ_n	: n. sınıfın varyanslarını
μ_t	: Ortalama Yoğunluk
SN	: Besin Kaynaklarının Sayısı
M	: Optimize Edilecek Parametre Sayısı
M_i	: i-inci güve'nin mevcut konumu
F_j	: j-inci alev'in mevcut konumu
$\vec{X}_n$	: n. şempanzenin konumu
$\vec{M}$	: Kaotik Vektör
w_n	: n. şempanzeye göre öğrenme oranı
$ \cdot $	: Öklid Mesafesi

1. GENEL BİLGİLER

1.1. Görüntü Segmentasyonu Genel Bakış

Görüntü eşikleme, görüntü işleme ve bilgisayarla görme alanında temel bir teknik olup piksel yoğunluk değerlerine göre görüntülerin farklı bölgelere ayrılmasını sağlar. Bu teknik, tıbbi görüntüleme, uzaktan algılama ve nesne tanıma gibi birçok uygulamada, analiz ve karar verme süreçleri için doğru segmentasyonun önemli olduğu durumlarda kilit rol oynar (Bhandari, Kumar, & Singh, 2015). Segmentasyon, bir görüntünün farklı nesneleri, dokuları veya ilgi alanlarını temsil eden anlamlı bölgelere ayrılmasını ifade eder. Örneğin, tıbbi görüntülemede tümör tespiti, organ sınırlarının belirlenmesi ve hastalıkların izlenmesi gibi görevlerde kullanılır. Uzaktan algılama alanında arazi kullanımı sınıflandırması ve çevresel izleme süreçlerinde segmentasyon önemli bir kolaylık sağlarken, endüstriyel uygulamalarda kusur tespiti ve kalite kontrolünde büyük katkı sağlar. Segmentasyonun önemi, karmaşık görüntü verilerini basitleştirerek analiz edilmesini kolaylaştırmasında ve anlamlı bilgilerin çıkarılmasını mümkün kılmasındadır. Bu nedenle, çeşitli disiplinlerde görüntü işleme sürecinin en önemli adımlarından biridir.

1.2. Görüntü Segmentasyonundaki Zorluklar

Aydınlatma koşullarındaki değişiklikler, gürültü ve nesne sınırlarının karmaşıklığı gibi faktörler nedeniyle segmentasyon zorlu bir süreçtir. Basitliği ve etkinliği nedeniyle, görüntü eşikleme teknikleri, görüntü segmentasyonunda yaygın olarak kullanılmaktadır. Bu yöntemler, bir görüntü içindeki belirli nesneleri, özellikleri veya bilgileri bölütleyebilmek için önceden tanımlanmış eşik değerlerini kullanır. Eşikleme tabanlı görüntü segmentasyonunda iki ana yaklaşım bulunmaktadır: İki seviyeli eşikleme ve çok seviyeli eşikleme. İki seviyeli eşikleme, tek bir eşik değeri kullanarak görüntüyü iki sınıfa ayırır; eşik değerinin altındaki gri tonları bir sınıfa, üzerindeki ise diğer sınıfa atanır. Buna karşılık, çok seviyeli eşikleme, önceden tanımlanmış bir dizi eşik değeri kullanarak görüntüyü birden fazla sınıfa böler ve görüntü içinde ayırık kümeleri tanımlar. Renkli görüntüler için segmentasyon, her renk kanalına (Kırmızı, Yeşil ve Mavi) ayrı eşik değerleri uygulanarak gerçekleştirilebilir. Her kanal için çok seviyeli eşikleme genellikle daha yüksek

segmentasyon doğruluğu sağlasa da bu yaklaşım hesaplama karmaşıklığını önemli ölçüde artırır. Renkli görüntü segmentasyonunda eşik değerlerinin tüm renk kanalları için ayrı ayrı belirlenmesi gerekmektedir (Cheng & Prayogo, 2014).

Çok seviyeli eşikleme genellikle segmentasyon doğruluğunu artırırken, hesaplama karmaşıklığını da önemli ölçüde yükseltir. Mevcut yöntemler, eşik seviyeleri arttıkça yüksek hesaplama maliyetleri, çeşitli görüntü türlerine uyum sağlama sınırlılığı ve gürültüye veya aydınlatma değişikliklerine karşı hassasiyet gibi sınırlamalarla karşı karşıyadır. Bu zorluklar, segmentasyon doğruluğunu korurken hesaplama verimliliğini artıran yenilikçi algoritmaların geliştirilmesini gerektirmektedir.

1.3. Çok Seviyeli Görüntü Segmentasyonunda Meta Segisel Algoritmaların Kullanımı

Görüntü histogramlarından optimal eşik değerlerini belirlemek için çeşitli yaklaşımlar önerilmiştir. Bunlar arasında en sık kullanılan yöntemler Kapur entropisi ve Otsu kriteridir. Kapur entropisi, gri seviyelerin olasılık dağılımını kullanarak segmente edilmiş sınıfların histogram entropilerini maksimize eden eşik değerlerini belirler. Otsu yöntemi ise, gri seviye sınıfları arasındaki varyansı maksimize eden eşik değerlerini seçer (Gad, 2022).

Eşikleme yaklaşımları, iki seviyeli segmentasyon problemlerini etkin bir şekilde çözerken, çok seviyeli segmentasyon için hesaplama karmaşıklığı ve maliyetler üstel olarak artmaktadır. Bu sorunu ele almak için araştırmacılar, hesaplama karmaşıklığını azaltmak ve segmentasyon performansını artırmak üzere meta-sezgisel arama algoritması (MSA) kullanımını önermişlerdir. Ancak, histogramların çok modlu olması nedeniyle çok seviyeli eşikleme tabanlı görüntü segmentasyonu karmaşık bir işlem haline gelmektedir. Ayrıca, her bir görüntü histogramı ve eşik seviye sayısı farklı zorlukta bir problemdir. Bu durum tüm optimizasyon problemleri için evrensel bir algoritma geliştirilmesini zorlaştırmaktadır. Sonuç olarak, literatürde bu zorlukları ele almak için birçok MSA geliştirilmiştir.

MSA'lar, doğal olaylardan ve sosyal davranışlardan esinlenen güçlü araçlardır. Bu algoritmalar, karmaşık arama uzaylarında keşif ve sömürü arasında denge kurarak sağlam çözümler sunarlar. Problemlere kolay uyarlanabilmeleri ve çok modlu fonksiyonları işleme yetenekleri, özellikle çok seviyeli eşikleme problemi için MSA'ları uygun çözüm araçları haline getirmiştir.

1.4. Görüntü Segmentasyonu Uygulamaları

Görüntü segmentasyonu, bilgisayarla görme ve görüntü işleme alanında temel bir unsurdur. Görüntülerdeki nesnelerin ve bölgelerin hassas bir şekilde belirlenmesi, çeşitli alanlarda analizi, karar verme süreçlerini ve otomasyonu güçlendirmektedir. Aşağıda, yüksek doğruluklu görüntü segmentasyonunun önemini vurgulayan uygulamalardan bazıları verilmiştir (Lang & Gao, 2025).

Nesne Tanıma ve Sınıflandırma:

- Görüntü segmentasyonu, bir görüntü içindeki nesnelerin tespit edilmesi ve sınıflandırılması için temel teşkil eder ve nesne tanıma sistemlerine büyük katkı sağlar.
- Otonom araçlar, güvenlik gözetimi ve robotik alanlarında yaygın olarak kullanılmaktadır; bu sayede otomatik navigasyon, tehdit tespiti ve akıllı karar verme mümkün olur.
- Yüksek doğruluklu segmentasyon, yüz tanımayı, yaya tespitini ve jest tanımayı geliştirerek insan-bilgisayar etkileşimini güçlendirir.

Tıbbi Görüntü Analizi:

- Tıbbi görüntülemede, doğru segmentasyon, organlar, tümörler ve damarlar gibi anatomik yapıların izole edilmesi ve analiz edilmesi açısından kritik öneme sahiptir (Qiao, Wu, Heidari, Zhao, & Chen, 2025).
- Tanı süreçlerinde, hastalıkların izlenmesinde ve tedavi planlamasında rol oynayarak tıbbi müdahalelere destek sağlar.
- Segmentasyon, yapay zeka destekli radyoloji araçlarının performansını artırarak hastalıkların erken tespitini sağlar.
- Uygulamalar arasında manyetik rezonans (MRI), bilgisayarlı tomografi (CT) ve ultrason görüntü analizi bulunmakta olup, sağlık profesyonellerine veriye dayalı klinik kararlar almada yardımcı olur.

Uydu ve Uzaktan Algılama:

- Uydu ve hava görüntülerinde, segmentasyon, arazi örtüsü sınıflandırması, çevresel değişikliklerin izlenmesi ve doğal afetlerin etkilerinin değerlendirilmesi için esastır.
- Segmentasyon, coğrafi uzaysal verilerden kritik bilgiler çıkararak kentsel planlama, orman kaybının izlenmesi ve tarım arazisi yönetimi süreçlerine katkı sağlar.

- Doğru segmentasyon, buz, su kütleleri ve bitki örtüsü sağlığı analizinde, iklim değişikliği çalışmalarında destek sunar.

Görüntü Düzenleme ve Artırma:

- Dijital sanat, fotoğrafçılık ve video üretiminde segmentasyon, hedefli değişiklikler ve iyileştirmeler için nesnelerin hassas bir şekilde izole edilmesini sağlar.
- Arka plan kaldırma, görüntü kompozisyonu ve özel efektlerde yaygın olarak kullanılır; bu sayede sorunsuz görsel entegrasyon sağlanır.
- Yapay zeka destekli araçlar, otomatik rötuş, akıllı kırpma ve içerik farkındalıklı doldurma gibi işlemler için segmentasyondan yararlanarak yazılımlardaki kullanıcı deneyimini geliştirir.

Artırılmış Gerçeklik ve Sanal Gerçeklik:

- Artırılmış gerçeklik (AR) ve sanal gerçeklik (VR) uygulamalarında doğru segmentasyon, sanal nesnelerin gerçek dünya ortamlarıyla doğal bir şekilde kaynaşmasını sağlama açısından kritik öneme sahiptir.
- Segmentasyon, gerçek zamanlı sahne anlayışını geliştirerek gerçekçi üst üste bindirmeleri, etkileşimli deneyimleri ve sürükleyici oyunları mümkün kılar.
- Segmentasyon, ön plan ve arka plan elemanları arasında doğru ayırım yaparak AR navigasyonunu, sanal giyim uygulamalarını ve jest tabanlı arayüzleri iyileştirir.

Endüstriyel Muayene ve Kalite Kontrol:

- İmalat ve üretimde segmentasyon, otomatik kusur tespiti ve kalite güvence süreçlerine katkı sağlar.
- Ürünlerin muayenesinde, yüzey kusurlarının tespitinde ve üretim verimliliğinin artırılmasında yüksek hassasiyet sağlar.
- Segmentasyon tabanlı yapay zeka modelleri, yarı iletken plakalar, tekstil ürünlerinde ve otomotiv bileşenlerinde anormallikleri tespit ederek atıkları ve operasyonel maliyetleri azaltır.

Bilimsel Araştırma ve Analiz:

- Astronomi, biyoloji ve kimya gibi bilimsel disiplinlerde segmentasyon, karmaşık görüntülerin analiz edilmesini sağlayarak anlamlı örüntülerin çıkarılmasını kolaylaştırır.
- Mikroskopik görüntü analizini destekler ve biyomedikal araştırmalarda hücre yapılarını, bakterileri ve doku anormalliklerini tanımlar.

- Astronomide segmentasyon, gök cisimlerinin sınıflandırılması, öte gezegenlerin tespiti ve kozmik olayların analizi için kullanılır.

Hassas Tarım:

- Akıllı tarım uygulamalarında segmentasyon, ürün izleme, zararlı tespiti ve verim tahmininde önemli rol oynayarak tarımsal üretkenliği optimize eder (Akay, Saleh, Farea, & Kanaan, 2022).
- Uzaktan algılama ve dron tabanlı görüntüleme, segmentasyonu toprak sağlığı değerlendirmesi, sulama sorunlarını tespit etme ve tarla değişkenliğini yönetme amacıyla kullanılır.
- Yapay zeka destekli segmentasyon araçları, tarımın sürdürülebilirliği artırmak ve kaynak kullanımını optimize etmek için veriye dayalı kararlar almalarına yardımcı olur.

1.5. Meta-sezgisel Arama Algoritmalarına Giriş

MSA'lar karmaşık optimizasyon problemlerini çözmedeki etkinlikleri nedeniyle mühendislik uygulamalarında oldukça popüler hale gelmiştir. Problem karmaşıklığı arttıkça, daha gelişmiş MSA'lara olan ihtiyaç daha da belirgin hale gelmektedir. Bu artan talep, birkaç temel faktörle desteklenmektedir (Poli, Kennedy, & Blackwell, 2007). İlk olarak, MSA'lar basit kavramlar ve yapılar üzerine kuruludur; bu da onları öğrenmesini ve uygulamasını kolaylaştırır. Ayrıca, türev-tabanlı mekanizmalar gerektirmediği için, gradyan bilgilerinin bilinmediği veya hesaplama açısından pahalı olduğu gerçek dünya mühendislik problemleri için oldukça uygundur. Bir diğer önemli avantaj ise yerel optimumlardan kaçınma yetenekleridir; bu, geleneksel optimizasyon algoritmalarının yaygın olarak karşılaştığı bir zorluktur. Ayrıca, Meta-Sezgisel Algoritmalar (MSA'lar), optimizasyon görevlerini birer "kara kutu" olarak ele alarak, önemli yapısal değişiklikler gerektirmeden çeşitli problemlere uygulanabilmeleri sayesinde esneklik sunar. Doğaları gereği paralel yapılara sahip olmaları, bu algoritmaları donanım üzerinde verimli bir şekilde uygulamaya uygun hâle getirir; bu da Özelleştirilebilir Donanımlar (FPGA gibi) aracılığıyla hesaplama performansının önemli ölçüde artırılmasını sağlar.

Optimizasyon algoritmaları genellikle iki ana kategoriye ayrılır: deterministik-tabanlı ve stokastik-tabanlı yaklaşımlar. Deterministik algoritmalar, kesinliklerine rağmen yerel optimumlara takılma ve yavaş yakınsama hızı gibi sorunlara sahiptir. Bunun aksine stokastik

algoritmalar arama uzayını daha etkili bir şekilde keşfetmek için tasarlanmıştır; bu sayede bu algoritmaların yerel minimumlara takılma olasılığı azalırken yakınsama hızları da arter. Bu avantajları nedeniyle, son araştırmalarda stokastik-tabanlı yöntemler oldukça dikkat çekmektedir. Bunlar arasında, Doğadan İlham Alan Algoritmalar (DİA) basitliği, esnekliği ve gradyan bilgisine bağımlılık olmadan yüksek boyutlu ve karmaşık problemleri çözebilmeleri nedeniyle öne çıkmaktadır. Araştırma bulguları, DİA'ların özellikle zorlu optimizasyon görevleri için uygun olduğunu doğrulamaktadır.

(Khishe, vd., 2021), DİA'ların en etkili alt sınıflarından biri, sürü zekası tabanlı algoritmalar; bu algoritmalar mühendislik uygulamalarında önemli başarılar göstermiştir. Bilim insanları ve mühendisler, bu yöntemleri arama uzayının detaylarını koruyabilme yetenekleri ve arama sürecinde karşılaşılan en iyi çözümleri saklama becerileri nedeniyle yaygın olarak kullanmaktadır. Ayrıca, bu algoritmaların parametre ayarlama ihtiyacının az olması ve kolay uygulanabilir olması, onları gerçek dünya optimizasyon sorunlarının çözümü için elverişli hale getirmektedir. Bu avantajlar nedeniyle, sürü zekası tabanlı MSA'lar çeşitli alanlarda mühendislik çözümlerini geliştirmede hala önemli bir rol oynamaktadır. Tablo 1'de literatürde kullanılan DİA sınıflandırılması sunulmuştur.

1.6. Araştırmanın Amaçları ve Katkıları

Bu tez çalışması, çok seviyeli eşikleme tabanlı görüntü segmentasyonu için yeni birkaç yaklaşım sunmaktadır. Çalışmada öncelikle görüntü eşikleme literatüründe en çok kullanılan 11 MSA'nın (Yapay Arı Kolonisi (ABC) (Karaboga & Basturk, 2007), Guguk Kuşu Arama (CS) (Gandomi, Yang, & Alavi, 2013), Diferansiyel evrim (DE) algoritması (Storn & Price, 1997), Gri Kurt Optimizasyonu (GWO) (Mirjalili, Mirjalili, & Lewis, 2014), Harris Şahini Optimizasyonu (HHO) (Heidari, vd., 2019), Güve-Alev Optimizasyonu (MFO) (Mirjalili, 2015), Parçacık sürüsü optimizasyonu (PSO) (Poli, Kennedy, & Blackwell, 2007), Sinüs-Kosinüs Algoritması (SCA) (Mirjalili, 2016), Simbiyotik organizmalar arama (SOS) (Cheng & Prayogo, 2014), Salp Sürü Algoritması (SSA) (Mirjalili, vd., 2017), Balina Optimizasyon Algoritması (WOA) (Mirjalili & Lewis, 2016)) segmentasyon performansı incelenmiştir. Bu MSA'lerden en başarılı ilk üç algoritma kullanılarak üç farklı çok aşamalı hibrid algoritma önerilmiştir.

Tablo 1. Doğadan ilham alan algoritmaların genel sınıflandırması

Yöntemler	Evrin temelli	Fizik temelli	Zeka temelli
Genetik Algoritmalar (GA) (Mathew, 2012)	✓		
Diferansiyel evrim (DE) algoritması (Storn & Price, 1997)	✓		
Sinüs-Kosinüs Algoritması (SCA) (Mirjalili, 2016)		✓	
Yapay Arı Kolonisi (ABC) (Karaboga & Basturk, 2007)			✓
Guguk Kuşu Arama (CS) (Gandomi, Yang, & Alavi, 2013)			✓
Gri Kurt Optimizasyonu (GWO) (Gandomi, Yang, & Alavi, 2013)			✓
Harris Şahini Optimizasyonu (HHO) (Gandomi, Yang, & Alavi, 2013)			✓
Güve-Alev Optimizasyonu (MFO) (Mirjalili, 2015)			✓
Salp Sürü Algoritması (SSA) (Mirjalili, vd., 2017)			✓
Parçacık sürüsü optimizasyonu (PSO) (Poli, Kennedy, & Blackwell, 2007)			✓
Simbiyotik organizmalar arama (SOS) (Cheng & Prayogo, 2014)			✓
Balina Optimizasyon Algoritması (WOA) (Mirjalili & Lewis, 2016)			✓
Şempanze Optimizasyon Algoritması (ChOA) (Khishe, vd., 2020)			✓
Ağırlıklı Şempanze Optimizasyon Algoritması (WChOA) (Khishe, vd., 2021)			✓

Daha sonraki aşamada Ağırlıklı Şempanze Optimizasyon Algoritmasına (Weighted Chimp Optimization Algorithm-WChOA) (Khishe & Mosavi, 2020), Uygunluk-Mesafe Dengesi (Fitness-Distance Balance) yöntemi (Kahraman, Aras, & Gedikli, 2020) uygulanarak yeni bir algoritma geliştirilmiştir.

Bu tezin temel amaçları şunlardır:

1. Çok seviyeli görüntü eşikleme problemi için etkili meta-sezgisel algoritmalar tasarlamak.
2. Çok seviyeli eşikleme bağlamında algoritmanın yakınsama davranışını ve arama alanını etkili bir şekilde keşfetme ve kullanma yeteneğini geliştirmek.
3. Önerilen algoritmayı referans veri setleri kullanarak doğrulamak ve mevcut en iyi yöntemlerle karşılaştırmak.

Bu tezin temel katkıları şu şekildedir:

- Görüntü segmentasyonu literatüründe çok sık kullanılmış 11 farklı MSA'nın büyük bir görüntü kümesi üzerinde ve farklı eşik seviyeleri için görüntü segmentasyon başarımları kıyaslanmıştır.
- Görüntü segmentasyonu için üç farklı çok aşamalı hibrit MSA önerilmiştir: MFO-PSO, MFO-SSA ve MFO-PSO-SSA.
- UMD yöntemi, WChOA algoritmasına entegre edilerek orijinal algoritmanın geliştirilmiş bir versiyonu tasarlanmıştır.
- Geliştirilen WChOA-UMD yönteminin çok seviyeli eşikleme tabanlı görüntü segmentasyonu problemindeki başarımı değerlendirilmiştir.
- Önerilen yaklaşımların çok seviyeli görüntü segmentasyonu performansı, çeşitli eşik seviyeleri üzerinde analiz edilmiştir. Algoritmaların performansı, iki farklı sonlandırma kriterine göre değerlendirilmiştir.
- Önerilen algoritmaların etkinliği, uygunluk değerleri, zirve sinyal-gürültü oranı (PSNR) ve yapısal benzerlik indeksi (SSIM), özellik benzerlik indeksi (FSIM) metrikleriyle doğrulanmıştır.

1.7. Literatür Özeti

Görüntü segmentasyonu, özellikle çok seviyeli eşikleme, tıbbi görüntüleme, uzaktan algılama ve nesne tanıma gibi çeşitli alanlarda geniş bir uygulama yelpazesi sunması nedeniyle son yıllarda büyük ilgi görmektedir. Çok seviyeli eşikleme ile ilişkili zorlukların

üstesinden gelmek için birçok meta-sezgisel algoritma kullanılmıştır; bu algoritmalar, segmentasyon doğruluğunu artırmayı ve hesaplama verimliliğini iyileştirmeyi hedeflemektedir. Bu bölümde, meta-sezgisel algoritmaların çok seviyeli eşikleme tabanlı görüntü segmentasyonunda uygulanmasını inceleyen literatürdeki öne çıkan bazı çalışmalar ele alınmıştır.

Meta-sezgisel optimizasyona dayalı çok seviyeli görüntü eşikleme çalışmaları genellikle iki gruba ayrılabilir. İlk grup çalışmalar, mevcut bir MSA'nın problemin çözümüne uygulanmasını ve rakip algoritmalarla karşılaştırılmasını içermektedir. İkinci grup çalışmalar ise, mevcut bir MSA'yı değiştirerek veya melez MSA'lar geliştirerek yeni bir algoritma tasarlamayı hedeflemekte ve böylece görüntü segmentasyonu performansını artırmayı amaçlamaktadır. Ancak her algoritmanın kendine özgü sınırlamaları bulunmaktadır. Bu nedenle araştırmacılar, algoritmadaki arama süreci stratejisini değiştirerek yöntemi iyileştirmeye veya algoritmaları birlikte kullanarak melez yöntemler geliştirmeye çalışarak performansı artırmaya ve karmaşıklığı azaltmaya odaklanmaktadır.

Mirjalili (2015), güvelerin transferse yönlendirme mekanizmasından esinlenerek Güve-Alev Optimizasyonu (MFO) algoritmasını tanıttı. Algoritma, optimizasyon problemlerinde keşif ve sömürüyü dengelemek için yapay ışıklar etrafındaki güvelerin spiral uçuş yollarını modellemektedir. MFO, 29 temel fonksiyon ve 7 gerçek dünya mühendislik problemi üzerinde test edilmiş ve Parçacık Sürü Optimizasyonu (PSO), Genetik Algoritma (GA) ve Yerçekimi Arama Algoritması (GSA) gibi diğer meta-sezgisel algoritmalarla karşılaştırıldığında rekabetçi performans sergilemiştir. İstatistiksel testler, karmaşık kısıtlı ve bilinmeyen arama uzayı problemlerini çözmedeki etkinliğini doğrulamıştır. Çalışma ayrıca MFO'yu deniz pervanesi tasarımı üzerine uygulayarak pratik faydasını daha da doğrulamıştır. Mirjalili vd. (2017), derin okyanuslardaki salpların sürü davranışını taklit eden biyolojiye dayalı bir optimizasyon tekniği olan Salp Sürü Algoritması'nı (SSA) tanıtmışlardır. Algoritma, lider salpın yiyecek kaynağına doğru hareket etmesini ve takipçi salpların liderlere göre pozisyonlarını güncellemesini modelleyen zincir şeklindeki hareketi temsil etmektedir. SSA, çeşitli temel fonksiyonlar ve gerçek dünya mühendislik problemleri üzerinde test edilmiş ve diğer meta-sezgisel algoritmalarla karşılaştırıldığında üstün performans göstermiştir. Su vd. (2022), COVID-19 X-ray görüntülerinin segmentasyonu için yapay arı kolonisi algoritması (ABC) ve geliştirilmiş versiyonu olan İşbirlikçi Eşevrimli Yapay Arı Kolonisi Algoritması CCABC'yi incelemişlerdir. Yatay ve dikey arama mekanizmalarını içeren iyileştirilmiş bir ABC algoritması olan CCABC'yi tanıtmışlar ve

optimizasyon performansını artırmışlardır. Ayrıca, segmentasyon işleminin etkinliğini artırmak için CCABC tabanlı çok seviyeli eşiklemeye dayalı görüntü segmentasyonu yöntemi önermişlerdir. Çalışma, CCABC'yi 30 temel fonksiyon kullanarak 15 algoritma ile karşılaştırmış ve CCABC'nin ABC ve diğer benzer algoritmalarından daha üstün performans gösterdiğini, optimal çözümleri bulma ve görüntü segmentasyon doğruluğunu artırma konusundaki yeteneğini ortaya koymuştur. Liu vd. (2023), hesaplama maliyetlerini azaltmak ve segmentasyon doğruluğunu artırmak amacıyla Şempanze İlhamlı Remora Optimizasyon Algoritması'nı (HCROA) çapraz entropi yöntemiyle birlikte kullanmışlardır. Sharma vd. (2022), Kapur, Tsallis ve bulanık entropi yöntemleri ile sınıflar-arası varyansı kullanan değiştirilmiş ateşböceği algoritmasını tanıtmışlardır. Yazarlar, aday çözüm popülasyonunun başlatılması için zıt-tabanlı öğrenme yöntemini kullanmışlar ve çok seviyeli görüntü segmentasyonu için optimal eşik değerlerini belirlemek amacıyla Levy uçuşu ve yerel arama tekniklerini dahil etmişlerdir. Houssein vd. (2022), tıbbi görüntülerde tümör tanımlaması için İyileştirilmiş Gri Kurt Optimizasyonu (IGJO) adlı yeni bir optimizasyon algoritması geliştirmişlerdir. IGJO'nun dayanıklılığı ve doğruluğu, bilinmeyen arama uzaylarına sahip farklı mühendislik ve gerçek dünya problemleri üzerinde test edilmiştir. Gharehchopogh ve Ibrikci (2024), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu için iyileştirilmiş Afrika Akbabası Optimizasyon Algoritması (AVOA) tanıtmışlardır. Kuantum dönüş kapısı ve ilişkilendirme stratejisi mekanizmalarını kullanarak AVOA'nın performansını, çeşitlilik artırarak ve yerel tuzığa düşme riskini azaltarak optimize etmişlerdir. Kumar vd. (2022), tarım görüntülerinin segmentasyonu için en iyi eşik değerlerini elde etmek üzere karga arama algoritması (CSA) ile özyinelemeli minimum çapraz entropi (R-MCE) yöntemini birleştirmişlerdir. Önerilen teknik, 20 tarım görüntüsü üzerinde test edilmiş ve diğer algoritmalarla karşılaştırıldığında segmentasyon doğruluğu ve kalitesinde iyileşme göstermiştir. Agrawal vd. (2022), çok seviyeli eşikleme renkli görüntü segmentasyonu için baskın renk bileşeni ve uyarlanabilir balina optimizasyon algoritması (DCC-AWOA) yöntemini önermişlerdir. Çalışmalarında Kapur entropisi ve kenar büyüklüğüne dayalı eşikleme gibi entropik ve entropik olmayan amaç fonksiyonlarını kullanmışlardır. Tan vd. (2021), değiştirilmiş bulanık entropiye dayalı çok seviyeli renkli görüntü eşikleme için, geliştirilmiş guguk kuşu arama algoritması (ICS) önermişlerdir. Renkli görüntülerde optimal çok seviyeli eşikler için geleneksel kapsamlı arama yöntemlerinin zaman alıcı doğasını ele almışlardır. ICS algoritması, standart guguk kuşu arama algoritmasının performansını artırmak için iki değişiklik içerir: uyarlanabilir kontrol parametresi mekanizması ve hibrit

arama stratejisi. Çalışma, ICS algoritmasını altı farklı optimizasyon algoritmasıyla karşılaştırmış ve amaç fonksiyon değeri, yakınsama hızı ve parametrik istatistiksel testler açısından üstün performansını göstermiştir.

Houssein vd. (2023), çok seviyeli eşikleme görüntü segmentasyonu için yakınsama hızını ve yerel arama verimliliğini artırmak amacıyla yığın tabanlı optimizasyon algoritması ile zıt-tabanlı öğrenmeyi birleştirmişlerdir (IHBO). Çalışma, IHBO tabanlı yöntemi CEC'2020 test seti üzerinde değerlendirmiş ve yedi iyi bilinen meta-sezgisel algoritma ile karşılaştırmıştır. Yazarlar, Otsu yöntemini amaç fonksiyonu olarak kullanarak IHBO algoritmasının performansını kapsamlı bir şekilde analiz etmişler ve kıyaslama görüntüleri için grafiksel ve istatistiksel sonuçlar sunmuşlardır. Wang vd. (2023), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu için geliştirilmiş altın çakal optimizasyonu (HGJO) önermişlerdir. CEC2022 test setini kullanarak algoritmalarının performansını ölçmüşler ve mevcut diğer algoritmalarla karşılaştırmışlardır. Sonuçlar, önerilen HGJO algoritmasının genel performans açısından diğer algoritmalarından üstün olduğunu ve orijinal özellikleri korurken görüntü karmaşıklığını azaltmadaki etkinliğini ortaya koymuştur. Abualigah vd. (2022), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu için Hibrit Deniz Avcısı Algoritması (MPA) ile Salpa Sür Algoritmasının (SSA) birleşimini (MPASSA) önermişlerdir. Önerilen algoritmanın performansını doğrulamak için çeşitli kıyaslama görüntüleri kullanmışlardır. Sonuçlar, önerilen MPASSA'nın literatürde yayınlanan diğer iyi bilinen optimizasyon algoritmalarından daha iyi performans sergilediğini göstermiştir. Eisham vd. (2023), mühendislik problemlerini çözmek için sinüs-kosinüs fonksiyonu ve Leopar Hidana Optimizasyonu (SHO) saldırı stratejisinin birleştiği Hidana Optimizasyonu Tabanlı Şempanze Optimizasyon Algoritması (SSC) adlı hibrit bir algoritma önermişlerdir. Bu algoritma, yüksek boyutlu problem çözümlerinde yavaş yakınsama hızı ve yerel optimumlara takılma gibi zorlukları ele almak için tasarlanmıştır. Swain vd. (2022), renkli uydu görüntülerinde çok seviyeli eşik seçimi için Diferansiyel üstel entropi (DEE) adında yeni bir amaç fonksiyonu ve denge-guguk kuşu arama optimizasyonu (ECSO) adlı yeni bir yöntem önermişlerdir. Önerilen yöntemin performansını Otsu yöntemi ve Kapur entropisi gibi geleneksel yöntemlerle karşılaştırmışlardır. Sonuçlar, önerilen tekniğin görüntü segmentasyonu kalitesi açısından geleneksel yöntemleri geride bıraktığını göstermiştir. Thomas ve Kumar (2023), özellikle Alzheimer hastalığı için MR beyin görüntülerinin segmentasyonunda Harris Şahin Optimizasyonu (HHO) kullanımını önermişlerdir. Model, segmentasyon için optimal eşik değerlerini seçmek üzere çok seviyeli

eşikleme ile optimizasyon algoritmasını birleştirmiştir. Yazarlar, modeli Alzheimer hastalarının MR beyin görüntüleri üzerinde test etmişler ve performans metrikleri açısından tatmin edici sonuçlar elde etmişlerdir. Ayrıca, Alzheimer hastalığı tespiti için çeşitli segmentasyon yaklaşımları ve makine öğrenimi modellerini tartışmışlar ve sağlık uygulamalarında doğru segmentasyonun önemini vurgulamışlardır.

Renugambal vd. (2023), çok seviyeli görüntü segmentasyonu verimliliğini artırmak için Hibrit Sinüs-Kosinüs Karga Arama Algoritması (SCCSA) önermişlerdir. Hibrit algoritmayı 12 standart görüntü üzerinde değerlendirmişler ve SCA, CSA ve ABC algoritmalarıyla performansını karşılaştırmışlardır. Deneysel sonuçlar, önerilen SCCSA algoritmasının çeşitli metrikler açısından diğer algoritmalarla sürekli olarak daha üstün performans gösterdiğini ortaya koymuştur. Ayrıca, önerilen algoritma ile diğer algoritmalar arasında anlamlı farklılıkları tespit etmek için Wilcoxon testi uygulamışlar ve bulgular, SCCSA algoritmasının diğer iyi bilinen algoritmalarla daha başarılı olduğunu doğrulamıştır. Akay vd. (2022), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu amacıyla, Öğrenme-Öğretme Tabanlı Optimizasyon Algoritması'nı (TLBO) iyileştirmek için Levy uçuş denklemlerini kullanma ve çerçeveye verimli alan göstergesi ekleme gibi değişiklikler yapmışlardır. Bu çalışmada, Öğrenme-Öğretme Tabanlı Yapay Arı Kolonisi (MTLABC) adlı değiştirilmiş bir versiyon önerilmiştir. Friedman testi ve Wilcoxon işaretli sıra testi, önerilen algoritma ile diğer optimizasyon algoritmaları arasında anlamlı bir fark olup olmadığını belirlemek için kullanılmıştır. Akan vd. (2024), ölüm oyunu optimizasyon (BRO) algoritmasını kullanarak çok seviyeli görüntü eşikleme yaklaşımı önermişlerdir. Yazarlar, BRO algoritmasının performansını AMO, PSO, BFO ve GA olmak üzere dört farklı algoritmayla 10 görüntü üzerinde karşılaştırmışlardır. Sonuçlar, BRO algoritmasının istikrarlı olduğunu ve standart sapma (SD) metriği açısından birinci sırada yer aldığını göstermiştir. Zhang vd. (2024), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu problemine çözüm sunmak için sinüs-kosinüs algoritmasıyla geliştirilmiş altın çakal optimizasyonu (SCGJO) önermişlerdir. SCGJO algoritmasını diğer evrimsel algoritmalarla karşılaştırmışlar ve iyi bir segmentasyon kalitesi ve genel optimal değer sergilediğini göstermişlerdir. Kang ve Hua (2023), Mumford-Shah (MSh) modeline dayalı çok seviyeli eşikleme tabanlı görüntü segmentasyonu algoritması önermişlerdir. Algoritma, MSh modelini optimal eşikleri belirlemek ve problemi çok amaçlı fonksiyon optimizasyonuna dönüştürmek için kullanmıştır. Yazarlar, önerilen algoritmanın görüntü segmentasyonu performansını doğrulamak için deneyler yapmışlar ve sonuçlar, önerilen algoritmanın en iyi

amaç fonksiyon değerine sahip olduğunu ve segmentasyon kalitesi ile yakınsama süresi açısından iyi performans gösterdiğini ortaya koymuştur. Wang vd. (2023), çok seviyeli eşiklemeye dayalı görüntü segmentasyonu için Karma Strateji Tabanlı İyileştirilmiş Balina Optimizasyon Algoritması (MSWOA) tanıtmışlardır. Bu yenilikçi algoritma, Balina Optimizasyon Algoritması (WOA) ilkelerini renkli görüntü segmentasyonu uygulamalarına odaklanarak karma stratejilerle birleştirmiştir. MSWOA yöntemi, k-nokta başlatma, doğrusal olmayan yakınsama faktörü ve uyarlanabilir ağırlık katsayısı gibi özellikleri içerecek şekilde segmentasyon sürecini optimize etmektedir. Bu unsurlar, algoritmanın arama yeteneğini ve yakınsama hızını artırarak daha doğru ve hızlı görüntü segmentasyonu sonuçları elde etmesini sağlamaktadır. Abdelrazek vd. (2024), görüntü segmentasyonu için optimal eşik değerlerini belirlemek amacıyla cüce fırvun farelerinin kaotik davranışlarından ilham alan yeni bir optimizasyon algoritması önermişlerdir. Kaos teorisi ve sürü zekasını birleştirerek, algoritma hesaplama maliyetlerini azaltırken segmentasyon doğruluğunu artırmaktadır. Çalışma, segmentasyon sürecini iyileştirmek için çapraz entropi yöntemini entegre etmiş ve geleneksel yaklaşımlara kıyasla üstün performans sergilemiştir.

Wang vd. (2025), pirinç bitki görüntülerinin çok seviyeli eşikleme segmentasyonu için geliştirilmiş Tonbalığı Sürü Optimizasyonu algoritması (SQGTSO) önermişlerdir. Geleneksel eşikleme yöntemlerinin sınırlamalarını aşmak için standart TSO algoritmasına üç temel iyileştirme entegre etmişlerdir: Sigmoid doğrusal olmayan ağırlıklandırma stratejisi, Kuadratik İnterpolasyon stratejisi ve elit sürü Genetik strateji. SQGTSO algoritması, on CEC2017 fonksiyonu üzerinde test edilmiş ve dokuz durumda diğer meta sezgisel algoritmalarından daha üstün performans göstermiştir. Pirinç bitki görüntüleri üzerinde yapılan karşılaştırmalı deneyler, SQGTSO'nun PSNR, SSIM, FSIM ve HPSI gibi birden fazla değerlendirme metriği açısından daha iyi segmentasyon kalitesi sergilediğini ortaya koymuş ve çok seviyeli eşikleme segmentasyonunu optimize etmedeki etkinliğini doğrulamıştır. Qiao vd. (2025), tıbbi görüntü segmentasyonunda global optimizasyon ve sinir mimarisi arama için geliştirilmiş Ağaç-Tohum Algoritması (WSTSA) önermişlerdir. WSTSA, standart TSA'nın keşif ve sömürü dengesini artırmak için solucan deliği ve salp sürüsü stratejilerini birleştirir. Ayrıca, WSTSA, derin öğrenme sinir mimarisi aramayı otomatikleştirmek için genetik algoritma ile birleştirilmiş ve hiper parametreleri optimize ederek arama doğruluğunu artırmıştır. CEC2017 kıyaslama fonksiyonları üzerinde yapılan kapsamlı deneyler, WSTSA'nın üstün optimizasyon performansını göstermiştir. Ayrıca, tıbbi görüntü segmentasyonu görevlerinde WSTSA-SegNet, birden fazla COVID-19 akciğer

BT veri setinde modern sonuçlar elde etmiş ve sinir ağ mimarisi araması ile hiper parametre ayarlamadaki etkinliğini doğrulamıştır. Houssein vd. (2024), BT görüntülerinden karaciğer hastalığı segmentasyonu için çok seviyeli eşikleme gerçekleştirmek amacıyla geliştirilmiş Yılan Optimizasyon Algoritması (SO-OBL) önermişlerdir. Belirsiz karaciğer sınırları ve tutarsız organ varlığı zorluğunu aşmak için standart Yılan Optimizasyonu (SO) algoritmasına zıt-tabanlı öğrenme (OBL) entegre etmişlerdir. SO-OBL yöntemi, CEC'2022 kıyaslama fonksiyonları üzerinde doğrulanmış ve on bir modern meta sezgisel algoritmadan daha üstün performans göstermiştir. Karaciğer BT taramaları üzerinde yapılan deneysel sonuçlar, SO-OBL'nin yüksek PSNR, SSIM, FSIM ve MSE değerleri elde ederek iyi bir segmentasyon doğruluğuna sahip olduğunu göstermiştir. Bu bulgular, SO-OBL'nin tıbbi görüntü segmentasyonu için çok seviyeli eşikleme optimizasyonundaki etkinliğini doğrulamıştır. Qiao vd. (2024), çok seviyeli eşikleme tabanlı görüntü segmentasyonu için Aritmetik Optimizasyon Algoritması (AOA) ve Harris Şahin Optimizasyonu (HHO)'yu birleştiren hibrit bir meta sezgisel algoritma önermişlerdir. Yazarlar, AOA'nın keşif yeteneğinde ve HHO'nun sömürü gücündeki avantajlarını kullanarak görüntü segmentasyonunda optimal eşikleri bulma zorluğunu ele almışlardır. Hibrit AOA-HHO algoritması, bu aşamaları dengelemek için tasarlanmış ve optimal eşikler için etkili küresel ve yerel arama sağlamıştır. Segmentasyon kalitesini değerlendirmek için özel bir uygunluk fonksiyonu, görüntü özelliklerinden türetilmiştir. Deneyler, farklı eşik seviyelerine (2'den 32'ye) sahip birden fazla test görüntüsü üzerinde gerçekleştirilmiştir. Sonuçlar, AOA-HHO'nun segmentasyon doğruluğu, uygunluk fonksiyonu değerleri, PSNR, SSIM ve yürütme süresi açısından tek başına AOA, HHO ve diğer meta sezgisel algoritmalarından daha üstün performans gösterdiğini ortaya koymuştur. Önerilen yöntem, daha yüksek PSNR ve SSIM değerleri elde ederek daha iyi görüntü kalitesi sağlamış ve hesaplama açısından verimli olduğu için tıbbi görüntüleme ve nesne tespiti gibi pratik uygulamalar için uygun olmuştur.

2. YAPILAN ÇALIŞMALAR

2.1. Çok Seviyeli Eşikleme Probleminin Tanımı

Görüntü eşikleme problemi, bir görüntüyü farklı sınıflara veya bölgelere ayırmak için optimal eşik değerlerini belirlemeye odaklanır. Temel hedef, görüntüyü anlamlı segmentlere ayıran bir dizi eşik belirlemektir; her bir segment belirli bir yoğunluk seviyesini veya sınıfını temsil eder. Segmentasyon sürecinde m adet eşik değeri kullanıldığında, görüntü $m+1$ bölgeye bölünür. En basit durumda, $m=1$ olduğunda, eşikleme problemine iki seviyeli eşikleme denir. Bu senaryoda, görüntü tek bir eşik değeri temelinde ön plan ve arka plan olmak üzere iki bölgeye ayrılır. İki seviyeli eşikleme, genellikle nesnelerin arka plandan ayrılmasının hedeflendiği, basit yoğunluk dağılımlarına sahip görüntülerde yaygın olarak kullanılır. Ancak, $m>1$ olduğunda problem çok seviyeli eşiklemeye dönüşür. Çok seviyeli eşikleme, birden fazla eşik değeri kullanarak görüntüyü birden fazla yoğunluk seviyesine veya sınıfa ayırmak için bu kavramı genişletir. Bu yaklaşım, özellikle karmaşık yoğunluk dağılımlarına veya birden fazla ilgi bölgesine sahip görüntülerde daha ince ve detaylı segmentasyon sağladığından önemlidir. Örneğin, tıbbi görüntülemede çok seviyeli eşikleme, bir görüntü içindeki farklı doku tiplerini veya anormallikleri ayırt etmek için kullanılabilir.

Matematiksel olarak, çok seviyeli eşikleme bir optimizasyon problemi olarak formüle edilir; buradaki hedef, bir görüntüyü $m+1$ bölgeye bölmek için en iyi eşik değerler kümesini, $[t_1, t_2, \dots, t_m]$ olarak belirlemektir. Her bir bölge, belirli bir piksel yoğunluk aralığına karşılık gelir. $f(x, y)$, görüntü I 'deki (x, y) konumundaki yoğunluğu temsil etsin. Görüntü, şu şekilde $m+1$ alt görüntüye bölünür:

$$\begin{aligned} I_0 &= \{f(x, y) \in I \mid 0 \leq f(x, y) \leq t_1 - 1\} \\ I_1 &= \{f(x, y) \in I \mid t_1 \leq f(x, y) \leq t_2 - 1\} \\ I_i &= \{f(x, y) \in I \mid t_i \leq f(x, y) \leq t_{i+1} - 1\} \\ &\vdots \\ I_m &= \{f(x, y) \in I \mid t_m \leq f(x, y) \leq 255\} \end{aligned} \tag{1}$$

Her bir I_i bölgesi, yoğunluk değerleri belirli bir eşik aralığında bulunan pikselleri temsil eder. I_0 , yoğunlukları $[0, t_1 - 1]$ arasında olan pikselleri içerirken, I_1 , $[t_1, t_2 - 1]$

arasındaki değerlere sahip pikselleri kapsar. Genel olarak, I_i , $[t_i, t_{i+1} - 1]$ aralığındaki yoğunluklara sahip piksellerden oluşur. Son bölge olan I_m ise, $[t_m, 255]$ arasındaki yoğunluk değerlerine sahip tüm pikselleri içerir.

Denklem (1), genellikle gri tonlamalı görüntülere uygulanmasına rağmen, RGB renkli görüntülere de genişletilebilir. Bu durumda, RGB görüntüsünün her bir kanalı (Kırmızı, Yeşil ve Mavi) ayrı bir gri tonlamalı görüntü olarak ele alınır ve eşikleme işlemi her bir kanala bağımsız olarak uygulanır. Bu, üç kanalın yoğunluk dağılımlarını dikkate alarak renkli görüntülerin daha incelikli segmentasyonunu sağlar. Eşik sayısı arttıkça çok seviyeli eşikleme, arama uzayının üstel olarak büyümesi nedeniyle hesaplama açısından maliyetli hale gelir. Geleneksel optimizasyon yöntemleri, özellikle geniş yoğunluk aralığına sahip veya gürültülü verilere sahip görüntülerde bu karmaşıklığı ele almada zorlanır. Bu zorlukları aşmak için MSA'lar, çözüm uzayını etkili bir şekilde keşfetmek ve neredeyse optimal eşik değerlerini bulmak için güçlü araçlar olarak öne çıkmıştır.

Bir görüntüde nesneleri arka plandan etkili bir şekilde ayırt eden optimal eşik değerlerini belirlemek için çeşitli yöntemler önerilmiştir. Bunlar arasında, bölütlenmiş bölgelerin entropisini maksimize eden Kapur entropisi (Kapur, Sahoo, & Wong, 1985) ve sınıf-arası varyansı maksimize eden Otsu yöntemi (Otsu, 1975) bulunur. Bu fonksiyonlar, en yaygın kullanılan parametrik olmayan eşikleme fonksiyonlarıdır. Bu yöntemler, entropi ve varyans gibi görüntü histogramının istatistiksel özelliklerine dayalı olarak segmentasyon kalitesini değerlendirir. Bu iki yaklaşım aşağıdaki alt bölümlerde açıklanmıştır.

2.1.1. Kapur Entropisi Tabanlı Eşikleme

Maksimum entropi olarak da bilinen Kapur fonksiyonu (Kapur, Sahoo, & Wong, 1985), bir görüntünün farklı bölgeleri arasındaki entropiyi maksimize ederek optimal eşik değerlerini belirlemeyi amaçlayan bir görüntü segmentasyonu tekniğidir. Bu bağlamda entropi, belirli bir bölgedeki bilgi miktarını veya belirsizliği temsil eder. Entropiyi maksimize ederek, Kapur fonksiyonu seçilen eşik değerlerinin ön plan ve arka plan bölgelerini etkili bir şekilde ayırt etmesini sağlarken aynı zamanda sınıflar arasındaki ayırt edici gücü korur.

Kapur entropisi, görüntü histogramındaki gri seviyelerin olasılık dağılımlarına dayalı olarak hesaplanır. $[th_1, th_2, \dots, th_n]$ eşik değerlerinin bir görüntüyü $n+1$ bölgeye

sınıflandırmak için kullanıldığı varsayılırsa, amaç fonksiyonu tüm bölütlenmiş bölgelerin entropilerinin toplamı olarak tanımlanır:

$$H(th_1, th_2, \dots, th_n) = H_1 + H_2 + \dots + H_n \quad (2)$$

Burada, $H_1, H_2 \dots H_n$ her bir Kapur entropisini temsil eder ve bu entropiler aşağıdaki şekilde hesaplanır:

$$\begin{aligned} H_1 &= - \sum_{j=0}^{th_1-1} \frac{p_j}{\omega_0} \ln \frac{p_j}{\omega_0}, & \omega_0 &= \sum_{j=0}^{th_1-1} p_j \\ H_2 &= - \sum_{j=th_1}^{th_2-1} \frac{p_j}{\omega_1} \ln \frac{p_j}{\omega_1}, & \omega_1 &= \sum_{j=th_1}^{th_2-1} p_j \\ & & & \vdots \\ H_n &= - \sum_{j=th_n}^{L-1} \frac{p_j}{\omega_n} \ln \frac{p_j}{\omega_n}, & \omega_n &= \sum_{j=th_n}^{L-1} p_j \end{aligned} \quad (3)$$

Bu denklemlerde $H_1, H_2 \dots H_n$, bölütlenmiş bölgelerin entropilerini, $\omega_1, \omega_2 \dots \omega_n$, her bir bölgenin olasılıklarını ifade eder ve bu olasılıklar, ilgili bölgedeki tüm gri seviyelerin olasılıklarının toplamı olarak hesaplanır. p_j , görüntü histogramındaki j gri seviyesinin olasılığını gösterir ve L , maksimum yoğunluk seviyesini temsil eder (örneğin, 8 bitlik gri tonlamalı görüntüler için 255).

Kapur yönteminin amacı, tüm bölgelerdeki toplam entropiyi temsil eden $H(th_1, th_2, \dots, th_n)$ amaç fonksiyonunu maksimize etmektir. Optimal eşik değerleri $t_1, t_2, \dots, t_n$, aşağıdaki optimizasyon problemi çözülerek elde edilir:

$$t^* = \operatorname{argmax} \left(\sum_{i=1}^n H_i \right) \quad (4)$$

2.1.2. Sınıf-arası Varyans Tabanlı Eşikleme (Otsu Yöntemi)

Otsu yöntemi (Otsu, 1975), sınıf-içi varyansı minimize ederken sınıf-arası varyansı maksimize ederek optimal eşik değerlerini belirleyen yaygın olarak kullanılan parametrik

olmayan bir segmentasyon tekniğidir. Bu yaklaşım, elde edilen segmentasyonun ön plan ve arka plan bölgelerini etkili bir şekilde ayırdığından emin olur.

Otsu yönteminin temel fikri, sınıf-arası varyans ile sınıf-içi varyans oranını maksimize ederek optimal eşik değerlerini hesaplamaktır. Sınıf-arası varyans, her bir sınıfın ortalama yoğunluğunun görüntünün genel ortalama yoğunluğundan olan karesel sapmalarının ağırlıklı toplamı olarak tanımlanır. Matematiksel olarak, amaç fonksiyonu aşağıdaki şekilde ifade edilir:

$$f(t) = \sigma_0 + \sigma_1 + \dots + \sigma_n \quad (5)$$

Burada, $\sigma_0, \sigma_1, \dots, \sigma_n$, her bir sınıfın varyansını temsil eder ve bu varyanslar aşağıdaki şekilde hesaplanır:

$$\sigma_0 = \omega_0(\mu_0 - \mu_T)^2, \quad \sigma_1 = \omega_1(\mu_1 - \mu_T)^2, \dots, \sigma_n = \omega_n(\mu_n - \mu_T)^2 \quad (6)$$

Burada, μ_T , giriş görüntüsünün ortalama parlaklık değerini (ortalama yoğunluk) temsil eder; μ_i , i 'nci sınıfın ortalama yoğunluğunu ifade eder ve bu değer, o sınıftaki gri seviyelerin olasılıkları kullanılarak hesaplanır. ω_i , i 'nci sınıfın olasılığını temsil eder ve bu da o sınıftaki piksellerin toplam piksel sayısına oranını gösterir. Her bir sınıfın ortalama yoğunluğu μ_i , aşağıdaki şekilde hesaplanır:

$$\mu_0 = \sum_{j=0}^{th_1-1} \frac{ip_j}{\omega_0}, \quad \mu_1 = \sum_{j=th_1}^{th_2-1} \frac{ip_j}{\omega_0}, \dots, \mu_n = \sum_{j=th_n}^{L-1} \frac{ip_j}{\omega_0} \quad (7)$$

Burada, $[th_1, th_2, \dots, th_n]$, görüntüyü $n+1$ bölgeye bölmek için kullanılan eşik değerleridir; p_i , görüntü histogramındaki i gri seviyesinin olasılığını temsil eder ve L , maksimum yoğunluk seviyesidir (örneğin, 8 bitlik gri tonlamalı görüntüler için 255).

Optimal eşik değerleri $th_1, th_2, \dots, th_n$, aşağıdaki amaç fonksiyonunu maksimize ederek elde edilir:

$$t^* = \operatorname{argmax} \left(\sum_{i=1}^n \sigma_i \right) \quad (8)$$

2.2. Meta-sezgisel Arama Algoritmaları (MSA)

Meta-sezgisel algoritmalar (MSA'lar), popülasyona dayalı arama stratejilerine sahip olan ve çeşitli optimizasyon problemlerinin çözümünde yaygın olarak kullanılan yöntemlerdir. Bu algoritmalar genel olarak, çözüm uzayında en iyi sonuçları bulmak amacıyla keşif ve sömürü dengesine dayalı bir arama süreci yürütür. Arama süreci, çözüm adaylarının seçilmesi ve bu adaylar üzerinden yeni çözümler üretilmesi şeklinde iki temel adımdan oluşur. Çeşitliliğin korunması ve yerel çözümlerden kaçınılması için çoğu algoritma rastgelelik veya mutasyon gibi mekanizmalar kullanır. Bu bağlamda, meta-sezgisel algoritmaların temel yapıları benzerlik gösterse de arama stratejileri, yakınsama hızları ve performansları açısından önemli farklılıklar gösterebilir. Bu çalışmada çok seviyeli görüntü eşikleme dayalı görüntü segmentasyonu literatüründe en yaygın kullanılan (ABC, CS, DE, GWO, HHO, MFO, PSO, SCA, SOS, SSA, ve WOA) algoritmalarının performansları karşılaştırılmıştır. Bu algoritmalar sonraki alt bölümlerde açıklanmıştır.

2.2.1. Yapay Arı Kolonisi (ABC) Algoritması

ABC algoritması, bal arılarının besin arama davranışından esinlenmiştir (Karaboga & Basturk, 2007). Besin arama süreci, besin kaynağının değeri ve türü, kovana olan yakınlığı, nektar konsantrasyonu ve nektarın hasat edilme kolaylığı gibi çeşitli faktörlerden etkilenir. Bu algorithmada, arı kolonisi üç ana gruba ayrılır: işçi arılar, kaşif arılar ve gözcü arılar. İşçi arılar, bilinen besin kaynaklarını sömürmekten sorumludur ve yiyeceği kovana getirir. Her bir besin kaynağının bir işçi arı ile ilişkilendirildiği varsayılır. Bu arılar, besin kaynağının kalitesini ve konumunu koloninin diğer üyelerine bilgi paylaşımı yoluyla iletirler. Bir besin kaynağı tükendiğinde, işçi arı ya kaşif arı ya da gözcü arıya dönüşür. Kaşif arılar çevreyi keşfederek yeni besin kaynakları bulurken, gözcü arılar kovanda kalır ve işçi arıların paylaştığı bilgileri kullanarak hangi besin kaynağını sömüreceklerine karar verirler. Optimizasyon problemlerinde, besin kaynaklarının konumları problemin potansiyel çözümlerini temsil eder ve nektar miktarı çözümün kalitesi veya uygunluğu ile ilişkilidir. ABC algoritmasının amacı, arıların besin arama davranışını simüle ederek bu çözümleri tekrarlı bir şekilde iyileştirmektir. Besin kaynaklarının başlangıç değerleri Denklem (9) kullanılarak üretilir. Burada, SN besin kaynaklarının sayısını ve M ise optimize edilecek parametre sayısını ifade eder:

$$x_{ij} = x_j^{min} + rand(0,1) * (x_j^{max} - x_j^{min}),$$

$$i=1, \dots, SN \quad j=1, \dots, M \quad (9)$$

Bu denklem, başlangıç çözümlerinin tanımlanmış arama uzayı içinde rastgele dağıtılmış olmasını sağlar. Her bir işçi arı için, yeni bir aday çözüm mevcut çözüm kullanılarak Denklem (10) temel alınarak oluşturulur:

$$v_{ij} = x_{ij} + \phi_{ij} * (x_{ij} - x_{kj}) \quad (10)$$

Burada, x_{ij} mevcut çözümü, x_{kj} rastgele seçilmiş bir komşu çözümü ve ϕ_{ij} , adım boyutunu kontrol eden -1 ile 1 arasında rastgele bir sayıyı temsil eder. Bu denklem, algoritmanın mevcut çözümün komşuluğunu keşfetmesine olanak tanır. Yeni çözümün uygunluk değeri $f(v_i)$, çözümün kalitesini değerlendiren Denklem (11) kullanılarak hesaplanır:

$$fitness_i = \begin{cases} 1/(1 + f_i), & f_i \geq 0 \\ 1 + abs(f_i), & f_i < 0 \end{cases} \quad (11)$$

Eğer yeni çözüm, mevcut çözümden daha iyi bir uygunluk değerine sahipse, eski çözüm yerine geçer. Aksi takdirde, eski çözüm korunur. Gözcü arılar, besin kaynaklarını uygunluk değerlerine göre seçer. Belirli bir besin kaynağını seçme olasılığı, Denklem (12) ile belirlenir:

$$p_i = \frac{fitness_i}{\sum_{i=1}^{SN} fitness_i} \quad (12)$$

2.2.2. Guguk Kuşu Arama (CS) Algoritması

(Gandomi, Yang, & Alavi, 2013) tarafından tanıtılan CS algoritması, guguk kuşlarının yavru bakımı parazitlik davranışından esinlenen bir meta-sezgisel optimizasyon yöntemidir. Bu davranışta, bir guguk kuşu tek seferde bir yumurta bırakır ve bunu rastgele olarak diğer kuş türlerinin yuvalarına yerleştirir. Konak kuşlar, guguk kuşu yumurtasını kuluçkaya

yatırabilir ve yavruyu büyütebilir ya da $P_\alpha \in (0,1)$ olasılığıyla yabancı yumurtayı fark edip yuvayı terk edebilir.

CS algoritmasının adımları şu şekildedir: Her bir guguk kuşu, önce rastgele bir yuva x_i^{t-1} seçer ve ardından bir Levy uçuş mekanizması kullanarak yeni bir yuva x_i^t belirler. Bu yuvalar bir amaç fonksiyonu F ile değerlendirilir. Eğer $F(x_i^t) > F(x_i^{t-1})$ koşulu sağlanıyorsa, guguk kuşu x_i^{t-1} yuvasını x_i^t ile değiştirir ve yumurtayı x_i^t yuvasına bırakır. Daha sonra, t iterasyonundaki tüm yuvalar sıralanarak en iyisi belirlenir. Bu süreçte, bazı düşük kaliteli yuvalar α olasılığına göre terk edilir ve onların yerine yeni yuvalar inşa edilir. Yeni bir yuva (veya çözüm) x_i^{t+1} , Denklem (13) kullanılarak hesaplanır; burada $step_length$, Levy dağılımından türetilen adım boyutunu temsil eder ve α bir ağırlık katsayısı olarak görev yapar:

$$x_i^{t+1} = x_i^t + \alpha \times step_length \quad (13)$$

2.2.3. Diferansiyel Evrim (DE) Algoritması

DE algoritması (Storn & Price, 1997), GA ile benzer şekilde çaprazlama, mutasyon ve seçim gibi evrimsel operatörleri kullanan popülasyon tabanlı bir optimizasyon tekniğidir. Ancak GA'da iyileştirilmiş çözümler üretmek için temel mekanizma çaprazlama iken, DE'nin esas olarak mutasyona dayandığı görülmektedir. Bu temel işlem, popülasyon içinde rastgele seçilen çözüm çiftleri arasındaki farklara dayalı olarak gerçekleştirilir.

D parametrelili bir optimizasyon probleminde, her bir çözüm D boyutlu bir vektör olarak temsil edilir. DE algoritması, NP çözüm vektöründen oluşan rastgele başlatılmış bir popülasyonla başlar ve bu çözümlerin kalitesini artırmak için iteratif olarak mutasyon, çaprazlama ve seçim işlemleri uygulanır. Her bir hedef vektör $x_{i,G}$ için, aşağıdaki denklem (14) kullanılarak bir mutant vektör oluşturulur:

$$v_{i,G+1} = x_{i,G} + K \cdot (x_{r1,G} - x_{i,G}) + F \cdot (x_{r2,G} - x_{r3,G}) \quad (14)$$

Burada $i, r_1, r_2, r_3 \in \{1, 2, \dots, NP\}$, indisler rastgele seçilir ve birbirinden farklı olduğundan emin olunur. Burada F , ölçeklendirme faktörü ve K , kombinasyon faktörüdür. Çaprazlama adımında, ebeveyn vektör mutant vektörle birleştirilerek Denklem (15) ile tanımlanan bir deneme vektörü $u_{ji,G+1}$ oluşturulur:

$$u_{ji,G+1} = \begin{cases} v_{ji,G+1} & \text{if } (rnd_j \leq CR) \text{ or } j = rn_i \\ q_{ji,G} & \text{if } (rnd_j > CR) \text{ or } j \neq rn_i \end{cases} \quad (15)$$

Burada $j = 1, 2, \dots, D$; $r_j \in [0,1]$ rastgele üretilen bir sayı, $CR \in [0,1]$ çaprazlama olasılığı ve $rn_i \in (1, 2, \dots, D)$ ise mutant vektörden en az bir genin kalıtımını garanti eden rastgele seçilmiş bir indistir.

Geleneksel evrimsel algoritmalarından farklı olarak, DE popülasyondaki tüm bireylerin uygunluk değerlerinden bağımsız olarak üreme sürecine katılmasına izin verir. Mutasyon ve çaprazlama işlemlerinden sonra, yeni üretilen yavru uygunluk değerlendirmesine tabi tutulur. Daha sonra bir seçim mekanizması uygulanır ve yavru, ebeveyn vektörle karşılaştırılır. Eğer yavru daha iyi bir uygunluk skoru elde ederse, popülasyondaki ebeveyn yerine geçer; aksi takdirde ebeveyn değişmeden kalır. Bu yinelemeli süreç, maksimum nesil sayısı veya istenen bir doğruluk eşiği gibi bir durdurma kriteri karşılanana kadar devam eder.

2.2.4. Gri Kurt Optimizasyon (GWO) Algoritması

GWO algoritması (Mirjalili, Mirjalili, & Lewis, 2014), doğadan esinlenilmiş bir optimizasyon tekniğidir ve vahşi doğadaki gri kurtların hiyerarşik liderlik yapısını ve avlanma stratejilerini taklit eder. Gri kurtlar, kesin bir sosyal yapı sergiler ve bu durum algoritmanın tasarımında yansıtılır. Kurt sürüsü dört seviyeye ayrılmıştır:

- Alfa (α): Lider, karar verme ve sürüyü yönlendirme sorumluluğuna sahiptir.
- Beta (β): İkinci sırada yer alan birey, alfanın karar verme sürecine yardımcı olur ve sürü disiplini sağlar.
- Delta (δ): Alfa ve beta bireylerini takip eden ancak en düşük sıradaki kurtlara hükmeden bireylerdir.
- Omega (ω): En düşük sıradaki üyelerdir, üst düzey tüm bireylere boyun eğer ve besine son erişim hakkına sahiptir.

Gri kurtların avlanma süreci üç temel aşamadan oluşur: (1) Avı izleme, kovalamak ve yaklaşma. (2) Avı çevreleyip taciz etmek ve tükenmesini sağlamak. (3) Nihai saldırıyı gerçekleştirmek. GWO algoritmasında optimizasyon, bu avlanma davranışına dayanarak modellenmiştir. Şu ana kadar bulunan en iyi çözüm α olarak belirlenirken, ikinci ve üçüncü en iyi çözümler sırasıyla β ve δ 'ya atanır. Geri kalan arama ajanları ise ω 'yı temsil eder ve

bu ajanlar, üst düzey üç liderin rehberliğini takip eder. Kurtlar, arama uzayını keşfetmek için dağılır ve daha sonra çözümleri iyileştirmek üzere bir araya gelir. Gri kurtların optimal çözüme doğru hareketini yöneten matematiksel model Denklem (16) ile verilmiştir:

$$\begin{aligned}\vec{D} &= |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \\ \vec{X}(t+1) &= \vec{X}_p(t) - \vec{A} \cdot \vec{D}\end{aligned}\tag{16}$$

Burada $\vec{X}_p(t)$, avın konumunu (optimal çözümü), $\vec{X}(t)$ bir arama ajanının (kurt) konumunu, $\vec{X}(t)$ av ile kurt arasındaki uzaklık vektörünü, $\vec{A}$ ve $\vec{C}$ ise keşif ve sömürüyü kontrol eden katsayı vektörlerini temsil eder. Bu katsayı vektörleri Denklem (17) ile tanımlanmıştır.

$$\begin{aligned}\vec{A} &= 2\vec{a} \cdot \vec{r}_1 - \vec{a} \\ \vec{C} &= 2 \cdot \vec{r}_2\end{aligned}\tag{17}$$

Burada $\vec{a}$, iterasyonlar boyunca 2'den 0'a doğru doğrusal olarak azalan bir parametredir ve keşiften sömürüye geçişi destekler. Rastgele vektörler $\vec{r}_1$ ve $\vec{r}_2$, $[0,1]$ aralığında düzgün dağılmıştır. $\vec{A}$ değerinin büyüklüğü, bir arama ajanının avdan (potansiyel çözümden) uzaklaşması veya ona yaklaşması durumunu belirler. Eğer $\vec{A} > 1$ ise, kurt avdan uzaklaşır ve bu durum küresel keşfi teşvik eder. Tersine, $\vec{A} < 1$ olduğunda, kurt avın daha yakınına hareket eder ve yerel sömürüye odaklanır. Bu denge, çözüm uzayında kapsamlı bir aramayı sağlayarak alt-optimal çözümlere erken yakınsamayı önler. Yinelemeli süreç, önceden tanımlanmış iterasyon sayısı veya optimal çözüme yakınsama gibi bir sonlandırma kriteri karşılanana kadar devam eder.

2.2.5. Harris Şahinler Optimizasyonu (HHO) Algoritması

HHO algoritması (Heidari, vd., 2019), Harris şahinlerinin iş birlikçi avlanma davranışını modelleyen doğadan esinlenilmiş bir meta-sezgisel tekniktir. Bu davranış, avı tespit etme, koordineli sürpriz saldırılar ve uyarlanabilir saldırı stratejilerinden oluşur. HHO, popülasyon tabanlı ve gradyan kullanan bir optimizasyon algoritmasıdır; avın kaçış

enerjisine bağılı olarak keşif ve sömürü arasında geçiş yapar. Harris şahinleri, av ararken çeşitli konumlara konar ve eşit olasılıkla (q) iki farklı konma stratejisi uygular. Şahinler ya:

- $q < 0.5$ ise, tavşanın (avın) konumuna göre diğer şahinlerin konumlarına dayalı olarak konarlar.
- $q \geq 0.5$ ise, rastgele yüksek ağaçlara konarlar.

Şahinlerin konum güncelleme denklemi Denklem (18) ile verilmiştir:

$$X(t+1) = \begin{cases} X_{rand}(t) - r_1 | X_{rand}(t) - 2r_2 X(t) & q \geq 0.5 \\ (X_{rabbit}(t) - X_m(t)) - r_3 (LB + r_4 (UB - LB)) & q < 0.5 \end{cases} \quad (18)$$

Burada $X(t+1)$, bir sonraki iterasyondaki şahinin konumunu, $X_{rabbit}(t)$ mevcut en iyi bilinen çözümü (tavşanın konumunu), $X_{rand}(t)$ rastgele seçilmiş bir şahinin konumunu, $X_m(t)$ tüm şahinlerin ortalama konumunu, r_1, r_2, r_3, r_4 , $(0,1)$ aralığında rastgele üretilen sayıları, LB ve UB ise problem değişkenlerinin alt ve üst sınırlarını temsil eder.

HHO, avın kaçış enerjisine dayalı olarak keşiften sömürüye dinamik olarak geçiş yapar. Kaçış enerjisi şu şekilde modellenir; $E = 2E_0(1 - t/T)$, burada:

- E , avın kaçış enerjisidir ve zamanla azalır.
- E_0 , $[-1,1]$ aralığında rastgele başlatılan bir değerdir.
- T , maksimum iterasyon sayısıdır.
- t , mevcut iterasyonu ifade eder.

Eğer $E < 0.5$ ise, şahinler yumuşak bir çevreleme manevrası gerçekleştirir; $E \geq 0.5$ için ise sert bir çevreleme saldırısı uygularlar. Bu uyarlanabilir mekanizma, algoritmanın yakınsama yeteneklerini güçlendirir.

2.2.6. Güve-Alev Optimizasyonu (MFO) Algoritması

MFO algoritması (Mirjalili, 2015), güvelerin benzersiz navigasyon davranışını taklit eden biyolojiye dayalı bir meta-sezgisel tekniktir. Doğada güveler, ay ışığına göre sabit bir açı koruyarak düz çizgilerde hareket etmelerini sağlayan çapraz yönelim adlı bir yöntem kullanırlar. Ancak yapay ışık kaynakları bu mekanizmayı bozar ve güveleri ışığa doğru sarmal hareketlerle yaklaştırmaya zorlar. Bu davranış, MFO algoritmasının arama mekanizmasının temelini oluşturur.

MFO algoritmasında her bir aday çözüm, arama uzayını keşfeden bir güve olarak temsil edilir. Herhangi bir ana kadar bulunan en iyi çözümler ise alevler olarak adlandırılır. Güvelerin alevlere doğru hareketi, keşif ve sömürü arasında etkili bir denge sağlamak için logaritmik sarmal bir desen izler. Matematiksel olarak, bu hareket aşağıdaki şekilde modellenmiştir:

$$M_i^{t+1} = S(M_i, F_j) \quad (19)$$

$$S(M_i, F_j) = D_i e^{bt} \cos(2\pi t) + F_j \quad (20)$$

Burada M_i^{t+1} , $t+1$ iterasyonunda i -inci güvenin güncellenmiş konumunu, M_i ve F_j sırasıyla i -inci güve ve j -inci alevin mevcut konumlarını temsil eder. $S(M_i, F_j)$, hareketi kontrol eden sarmal fonksiyonu, b , logaritmik sarmalın şeklini kontrol eden bir sabiti, t ise, $[-1,1]$ aralığında rastgele üretilen bir sayı ifade eder. D_i , i -inci güve ile j -inci alev arasındaki mesafedir ve aşağıdaki denklemle hesaplanır:

$$D_i = |F_j - M_i| \quad (21)$$

Bu logaritmik sarmal, güvelerin alevlere doğru yavaşça yaklaşmasını sağlarken aynı zamanda belirli bir rastgelelik derecesini korur; bu durum arama sürecinde çeşitliliği sürdürmeye yardımcı olur. t parametresi, bir güvenin alevlere ne kadar yaklaştığını kontrol eder; $t = -1$ olduğunda güve alevlere en yakın konumdadır ve $t = 1$ olduğunda ise en uzak konumdadır.

Sömürüyü iterasyonlar boyunca artırmak için MFO, alev sayısını uyarlanabilir şekilde azaltır. Eğer güveler, arama süreci boyunca tüm alevlere göre konumlarını güncelleseydi, çözümlerin çok fazla dağılmasına neden olarak yakınsamayı engelleyebilirlerdi. Bu sorunu çözmek için MFO, aşağıdaki uyarlanabilir alev azaltma formülünü kullanır:

$$N_f = \text{round}(N - l \times \frac{N - 1}{T}) \quad (22)$$

Burada N_f , mevcut alev sayısı, N , başlangıçtaki alev sayısı, l , mevcut iterasyonu ve T , maksimum iterasyon sayısını temsil eder.

2.2.7. Parçacık Sürü Optimizasyonu (PSO) Algoritması

PSO (Poli, Kennedy, & Blackwell, 2007), kuş ve balıkların sosyal davranışlarından esinlenen popülasyon tabanlı bir optimizasyon tekniğidir. PSO'da, basit ajanlar olan parçacıklar (particles), arama uzayında hareket ederken kendi deneyimlerini ve komşularının deneyimlerini kullanarak yollarını ayarlarlar.

Her bir parçacık üç adet D-boyutlu vektör tutar: Mevcut konum $\vec{x}_i$, hareketi belirleyen hız $\vec{v}_i$, bulduğu en iyi çözümü temsil eden bireysel en iyi konum p_{best_i} .

Her bir iterasyonda, uygunluk fonksiyonu parçacığın mevcut konumunda değerlendirilir. Eğer bu yeni konum önceki en iyisinden daha iyi ise, p_{best} buna göre güncellenir. Tüm parçacıkların hareketini etkileyen küresel en iyi parçacık g_{best} (şimdiye kadar bulunan en iyi çözüm) olarak tanımlanır. Bu süreci matematiksel olarak tanımlamak için, iterasyon t 'deki bireysel en iyi konum p_{best}^t ve küresel en iyi konum g_{best}^t aşağıdaki şekilde belirlenir:

$$p_{best_i}^t = x_i^* | f(x_i^*) = \min \{f(x_i^k)\} \quad (23)$$

$$g_{best}^t = x_*^t | f(x_*^t) = \min \{f(x_i^k)\} \quad (24)$$

Burada i , parçacık indeksini temsil eder ve $\{1, 2, \dots, N\}$ aralığındadır, N toplam parçacık sayısını, k ve t iterasyon indekslerini ($k \in \{1, 2, \dots, t\}$) gösterir, f , optimize edilecek (minimize edilecek) amaç fonksiyonunu ve x , k . iterasyondaki i parçacığının konumunu ifade eder. Her bir parçacığın hızı ve konumu aşağıdaki denklemler kullanılarak güncellenir:

$$v_i^{t+1} = \omega v_i^t + c_1 r_1 (p_{best_i}^t - x_i^t) + c_2 r_2 (g_{best_i}^t - x_i^t) \quad (25)$$

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (26)$$

Burada v , hız vektörünü, x , konum vektörünü, ω , keşif ve sömürü arasında denge kurmaya yardımcı olan atalet ağırlığını, c_1 ve c_2 , bireysel en iyi ve küresel en iyi konumların etkisini kontrol eden ivme katsayılarını, r_1 ve r_2 , $[0,1]^D$ aralığında rastgele üretilen vektörleri (D , problemin boyutu veya parametre sayısıdır) temsil eder. Bu yinelemeli güncellemeler sayesinde sürü, çeşitliliği korurken yerel optimumlardan kaçınarak giderek bir optimal çözüme yakınsar.

2.2.8. Sinüs Kosinüs Algoritması (SCA)

SCA (Mirjalili, 2016), optimizasyon problemlerini çözmek için sinüs ve kosinüs fonksiyonlarını kullanan bir meta-sezgisel optimizasyon tekniğidir. Birçok stokastik popülasyon tabanlı optimizasyon algoritması gibi, SCA optimizasyon sürecini iki ana aşamaya ayırır: keşif ve sömürü.

- Keşif Aşaması: Algoritma, aday çözümlere rastgelelik ekleyerek arama uzayında umut verici bölgeleri belirlemeye çalışır.
- Sömürü Aşaması: Algoritma, optimal çözüme yakınsamak için bu çözümlere küçük, kontrollü değişiklikler yaparak onları iyileştirir.

SCA, çözümlerin konumlarını aşağıdaki denklemleri kullanarak günceller:

$$\begin{aligned} X_i^{t+1} &= X_i^t + r_1 \times \sin(r_2) \times |r_3 P_i^t - X_i^t| \\ X_i^{t+1} &= X_i^t + r_1 \times \cos(r_2) \times |r_3 P_i^t - X_i^t| \end{aligned} \quad (27)$$

Burada X_i^t , t . iterasyonda i . çözümün mevcut konumunu, P_i hedef konumu, r_1, r_2 ve r_3 hareketi etkileyen ve keşif ile sömürü arasında dengeyi sağlayan rastgele sayıları temsil eder. Sinüs ve kosinüs fonksiyonları arasındaki geçiş, bir olasılık faktörü olan r_4 tarafından aşağıdaki şekilde belirlenir:

$$X_i^{t+1} = \begin{cases} X_i^t + r_1 \times \sin(r_2) \times |r_3 P_i^t - X_i^t| & r_4 < 0.5 \\ X_i^t + r_1 \times \cos(r_2) \times |r_3 P_i^t - X_i^t| & r_4 \geq 0.5 \end{cases} \quad (28)$$

SCA'daki dört ana parametre farklı roller üstlenir:

- r_1 , hareket yönünü kontrol eder ve bir sonraki konumun arama bölgesinin içinde mi yoksa dışında mı olacağını belirler.
- r_2 , aday çözümün hedefe doğru ne kadar yaklaşacağını veya hedeften ne kadar uzaklaşacağını etkiler.
- r_3 , hedefe bir ağırlık atar; bu ağırlık, etkiyi artırabilir ($r_3 > 1$) veya azaltabilir ($r_3 < 1$).
- r_4 , sinüs ve kosinüs tabanlı hareket arasında olasılıksal olarak geçiş yapar.

2.2.9. Simbiyotik Organizmalar Arama (SOS) Algoritması

SOS algoritması (Cheng & Prayogo, 2014), canlı organizmalar arasındaki doğal simbiyotik ilişkilerden esinlenmiştir. Bu algoritma, organizmalar arasındaki etkileşimleri modelleyerek bir ekosistemde hayatta kalma şanslarını artırmayı hedefler. SOS, bu etkileşimleri üç türde kategorize eder: karşılıklılık, ortakçılık ve asalaklık. SOS, aday çözümlerden oluşan rastgele üretilmiş bir popülasyonla başlar; bu popülasyon bir ekosistem olarak adlandırılır. Her bir çözüm, amaç eğerini iyileştirmek ve optimal çözüme doğru ilerlemek için diğerleriyle etkileşime giren bir organizma olarak ele alınır.

Karşılıklılık Aşaması

İki organizma X_j ve X_i , her ikisine de fayda sağlayacak şekilde etkileşime girer. Güncellenen konumları aşağıdaki gibi hesaplanır:

$$\begin{aligned} X_{i_{new}} &= X_i + rand(0,1) * (X_{best} - Mutual_vector * BF_1) \\ X_{j_{new}} &= X_j + rand(0,1) * (X_{best} - Mutual_vector * BF_2) \end{aligned} \quad (29)$$

Burada $Mutual_vector = (X_i + X_j)/2$, paylaşılan faydayı temsil eder; BF_1 ve BF_2 (rastgele olarak 1 veya 2 değerine atanır), her bir organizma için fayda düzeyini belirler ve X_{best} , şu ana kadar bulunan en iyi çözümü ifade eder.

Ortakçılık Aşaması

Bu aşamada, bir organizma fayda sağlarken diğer organizma etkilenmez. Rastgele seçilmiş bir organizma X_j , X_i ile etkileşime girer ve X_i 'nin yeni konumu aşağıdaki gibi güncellenir:

$$X_{i_{new}} = X_i + rand(-1,1) * (X_{best} - X_j) \quad (30)$$

Asalaklık Aşaması

Bir organizma X_i 'ye dayalı olarak yapay bir parazit, "Parazit Vektörü" adıyla oluşturulur. Başka bir organizma X_j , konak olarak seçilir. Eğer Parazit Vektörü, X_j 'den daha iyi bir uygunluk değerine sahipse, ekosistemde X_j 'yi yerine geçer. Aksi takdirde, X_j değişmeden kalır ve bu parazite karşı bağışıklık kazanır.

2.2.10. Salp Sürüsü Algoritması (SSA)

SSA (Mirjalili, vd., 2017), derin sularda salpların sürü davranışını taklit eden biyolojiye dayalı bir optimizasyon tekniğidir. Doğada salplar, bir salp zinciri oluşturur; bu zincirde öncü salp rehberlik yapar ve izleyen salplar konumlarını buna göre ayarlar. Bu davranış, popülasyonu iki gruba ayırarak matematiksel olarak modellenmiştir: liderler, zincirin önündeki salplardır ve hareketi yönlendirme sorumluluğunu üstlenirler; izleyenler ise lideri takip eden geri kalan salplardır. Diğer sürü zekâ algoritmalarına benzer şekilde, salpların konumları, n boyutlu bir arama uzayında temsil edilir; burada n , optimizasyon problemindeki değişken sayısıdır. Tüm sürünün konumları, iki boyutlu bir konum matrisi x 'te saklanır. Salplar, toplu halde bir besin kaynağı F 'ye doğru hareket ederler; bu besin kaynağı, optimal çözümü temsil eder. Liderin konumu aşağıdaki denklem (31) kullanılarak güncellenir:

$$x_j^1 = \begin{cases} F_j + c_1 ((ub_j - lb_j)c_2 + lb_j) & c_3 \geq 0 \\ F_j - c_1 ((ub_j - lb_j)c_2 + lb_j) & c_3 < 0 \end{cases} \quad (31)$$

Burada x_j^1 , j . boyutta liderin konumunu (ilk salp), F_j , j . boyutta besin kaynağının konumunu, ub_j ve lb_j , arama uzayının üst ve alt sınırlarını, c_1 , c_2 ve c_3 ise keşif ve sömürü arasında denge sağlayan rastgele değişkenleri temsil eder. c_1 , SSA'daki en önemli parametredir çünkü keşif ve sömürü arasındaki dengeyi sağlar ve aşağıdaki şekilde tanımlanır:

$$c_1 = 2e^{(\frac{4l}{L})^2} \quad (32)$$

Burada l , mevcut iterasyonu ve L , maksimum iterasyon sayısını temsil eder. Parametreler c_2 ve c_3 , $[0,1]$ aralığında düzgün (uniform) dağılım kullanılarak rastgele üretilir. Bu parametreler, j . boyutta bir sonraki konumun pozitif veya negatif sonsuzluğa doğru hareket edip etmeyeceğini ve adım büyüklüğünü belirler. İzleyenlerin konumları ise Newton hareket denklemi (33) kullanılarak güncellenir:

$$x_j^i = \frac{1}{2}at^2 + v_0t \quad (33)$$

Burada x_j^i, j . boyutta i . izleyen salpın konumunu, t , zaman adımını (iterasyon sayısını), v_0 , başlangıç hızını ve a , ivmeyi temsil eder. İvme a , bu şekilde hesaplanır: $a = \frac{v_{final}}{v_0}$, burada $v = \frac{(x-x_0)}{t}$ dir.

Optimizasyon problemlerinde zaman, iterasyon sayısı ile temsil edildiğinden, iterasyon adımını $t = 1$ ve başlangıç hızını $v_0 = 0$ olarak kabul ederiz. Bu durum, denklemi aşağıdaki şekilde basitleştirir:

$$x_j^i = \frac{1}{2}(x_j^i + x_j^{i-1}) \quad (34)$$

Bu denklem, her bir izleyen konumunu bir önceki izleyen konumuna göre ayarlayarak, besin kaynağına doğru toplu olarak yakınsayan bir salp zinciri oluşturmasını sağlar. Lider için Denklem (31) ve izleyenler için Denklem (34) birleştirilerek, SSA salpların kolektif hareketini etkili bir şekilde modelleyebilir ve sürüyü arama uzayında verimli bir şekilde keşfetmeye ve sömürmeye olanak tanır.

2.2.11. Balina Optimizasyon Algoritması (WOA)

WOA (Mirjalili & Lewis, 2016), kambur balinaların kabarcık-ağ avlanma stratejisinden esinlenen bir meta-sezgisel tekniktir. Bu balinalar, işbirlikçi bir beslenme davranışı sergiler; yüzeye yakın balık sürülerini çevreler ve spiralli hava kabarcıkları oluşturarak avlarını tuzağa düşürürler. WOA, bu akıllı avlanma sürecini üç temel mekanizma ile simüle eder: avın çevrelenmesi, kabarcık-ağ saldırısı ve av arama. Kambur balinalar, avlarının konumunu belirleyebilir ve ona doğru hareket ederler. WOA'da, herhangi bir ana kadar bulunan en iyi aday çözüm avı temsil eder ve kalan çözümler konumlarını buna göre günceller. Bu davranış matematiksel olarak aşağıdaki şekilde formüle edilmiştir:

$$\begin{aligned} \vec{D} &= |\vec{C} \cdot \vec{X}_{best}(t) - \vec{X}(t)| \\ \vec{X}(t+1) &= \vec{X}_{best}(t) - \vec{A} \cdot \vec{D} \end{aligned} \quad (35)$$

Burada $\vec{X}_{best}(t)$, t iterasyonundaki en iyi çözümü, $\vec{A}$ ve $\vec{C}$, keşif ve sömürüyü etkileyen katsayı vektörlerini, $\vec{D}$ ise bir balinanın en iyi çözüme olan uzaklığını temsil eder. $\vec{A}$ ve $\vec{C}$ vektörleri aşağıdaki şekilde tanımlanır:

$$\begin{aligned}\vec{A} &= 2\vec{a}.\vec{r} - \vec{a} \\ \vec{C} &= 2.\vec{r}\end{aligned}\tag{36}$$

Burada $\vec{a}$, 2'den 0'a doğru doğrusal olarak azalan bir değerdir ve $\vec{r}$, $[0,1]$ aralığında rastgele üretilen bir vektördür. Av konumu belirlendikten sonra, WOA iki avlanma stratejisi arasında geçiş yapar:

Daralan Çevreleme Mekanizması:

Bu strateji, arama yarıçapını kademeli olarak azaltır ve çözümlerin en iyi aday çözüm etrafında toplanmasını sağlar.

Spiral Konum Güncelleme:

WOA, balinaların avlarının etrafında spiralli hareketini modellemek için yeni bir arama ajanının konumunu aşağıdaki denklemle günceller:

$$X(t+1) = \vec{D}'.e(bl).cos cos(2\pi l) + \vec{X}_{best}(t)\tag{37}$$

Burada b , logaritmik spiral şeklini tanımlayan bir sabittir, l , $[-1,1]$ aralığında rastgele üretilen bir sayıdır ve $\vec{D}'$, en iyi ajan ile mevcut ajan arasındaki mesafeyi temsil eder. WOA, balinaların henüz keşfedilmemiş bölgelere rastgele hareket etmesine izin vererek arama sürecini çeşitlendiren bir mekanizma da içermektedir. Bu durum, $\vec{A}$ değerleriyle kontrol edilir. Eğer $\vec{A} > 1$ ise, arama ajanları en iyi çözümden uzaklaşır ve bu da arama uzayının daha geniş bir şekilde keşfedilmesini sağlar.


2.3. Önerilen Çok Aşamalı Hibrit Algoritmalar

Bu çalışmada, görüntü segmentasyonundaki çok seviyeli eşikleme zorluklarını çözmek için üç yeni çok aşamalı hibrit meta sezgisel algoritma önerilmiştir. Bu algoritmalar büyük bir görüntü kümesi üzerinde çeşitli eşikleme seviyeleri için gerçekleştirilen deneysel çalışmalar sonucunda en başarılı olan MFO, PSO ve SSA'nın birleştirilmesi ile

tasarlanmıştır. Çalışmada çok seviyeli hibrit optimizasyon yöntemleri Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu Algoritması (MFO-PSO), Güve-Alev Optimizasyonu-Salp Sürüsü Algoritması (MFO-SSA) ve Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu-Salp Sürüsü Algoritması (MFO-PSO-SSA) önerilmiştir. Bu algoritmalar, hesaplama verimliliğini, segmentasyon doğruluğunu ve dayanıklılığını artırmak için birden fazla optimizasyon tekniğini birleştirir. Her bir yöntem, optimal eşik değerlerini aramak için keşif ve sömürü arasında etkili bir denge kurar. Bu algoritmaların uygulama detayları, iş akışları ve sözde kodları aşağıdaki bölümlerde açıklanmaktadır.

2.3.1. Hibrit Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu Algoritması (MFO-PSO)

Önerilen çok aşamalı hibrit MFO-PSO algoritması, optimizasyon sürecini iki aşamaya bölen güçlü bir optimizasyon çerçevesi oluşturmak için MFO ile PSO'yu birleştirir. Tek bir meta sezgisel algoritmaya bağlı kalmak yerine, bu yaklaşım MFO ve PSO'yu sıralı olarak kullanır. İlk aşamada, ateşböceklerinin ışık kaynaklarına doğru spiral hareketinden esinlenen MFO, maksimum uygunluk değerlendirmelerinin yarısı ($\max FEs/2$) için optimizasyon algoritması olarak görev yapar. Bu aşama, MFO'nun basit yapısı, arama hızı ve arama uzayındaki çeşitli bölgeleri etkili bir şekilde keşfetme yeteneği sayesinde erken yakınsamayı önlerken diğer algoritmalarla kolay entegrasyon sağlar. İkinci aşamada ise, sürüdeki parçacıkların sosyal davranışını model alan PSO, kalan uygunluk değerlendirmelerini devralır. PSO, umut verici bölgeleri etkili bir şekilde sömürerek çözümleri iyileştirir. Basit uygulama, az sayıda kontrol parametresi ve güçlü yakınsama performansı gibi avantajlar sunar. Bu iki algoritmayı birleştirerek, MFO-PSO dengeli bir arama stratejisi elde eder; MFO'nun spiral hareketi yerel optimumlardan kaçınmak için keşfi güçlendirirken, PSO'nun hız tabanlı güncellemeleri yüksek kaliteli çözümlere daha hızlı yakınsamayı sağlamak üzere etkili sömürü sağlar. Bu da onu çok seviyeli eşikleme gibi karmaşık optimizasyon problemleri için oldukça uygun kılar. Çok aşamalı hibrit MFO-PSO algoritmasının akış şeması Şekil 1'de sunulmuş olup sözde kodu Algoritma 1'de verilmiştir.



Şekil 1. Çok aşamalı hibrit MFO-PSO algoritmasının akış şeması

Algoritma 1. MFO-PSO Algoritmasının Sözde Kodu

```

1  Girdi: Probleme özgü parametreler (p), Değişken sayısı (dim), Maksimum
   iterasyon sayısı (Max_iteration)
2  Çıktı: Bulunan en iyi çözüm (bestSolution), En iyi çözümün uygunluk değeri
   (bestFitness)
3  Başla
4  N, lb, ub, dim, Iter=1 parametrelerini başlat
5  // MFO Aşaması
6  Denklem (22) kullanarak alev sayısını (FlameNumber) güncelle
7  Moth konumlarını M'yi ve uygunluk değerlerini OM'yi başlat
8  Iter ≤ Max_iteration / 2 yap (İterasyon sayısının yarısına ulaşılmadı)
9  // Moth'ları sırala ve alevleri güncelle
10 if Iter == 1 ise
11     F = sort(M) ; // en iyi alevler
12     OF = sort(OM) ; // en iyi alev uygunluk
13 else
14     F = sort(Mt-1, MT) ; // önceki en iyi alevler
15     OF = sort(Mt-1, MT) ; // önceki en iyi alev uygunluk
16 end if
17 // Spiral hareket kullanarak moth konumlarını güncelle
18 for i = 1 to N yap
19     for j = 1 to dim yap
20         t ve a'yı güncelle (t, [a,1] aralığında rastgele bir sayıdır,
           burada a, iterasyon sürecinde -1'den -2'ye doğrusal olarak
           azalır)

```

```


21         |         |         |         İlgili moth'a göre Denklem (21) kullanarak D'yi hesapla
22         |         |         |         İlgili moth'a göre Denklem (19) ve (20) kullanarak M(i,j)
23         |         |         |         matrisini güncelle
24         |         |         |         end for
25         |         |         |         İterasyonu güncelle
26     end while // MFO Optimizasyon Döngüsünün Sonu
27     // PSO Aşaması
28     nPop, w, wdamp, c1, c2, VelMax, VelMin parametrelerini başlat
29     // Parçacıkları MFO sonuçları ile başlat
30     for i = 1 to nPop yap
31         // MFO'dan elde edilen en iyi çözümler, PSO aşamasına girdi olarak
32         // aktarılır
33         particle(i).Position = Moth_pos(i) // Parçacıkların konumlarını başlat
34         particle(i).Cost = Moth_fitness(i) // Parçacıkların hızını başlat
35          $P_{best}^0 \leftarrow x_i^0$  //  $P_{best}$  başlangıç konumuna göre başlat
36     end for
37     Denklem (24)'ü uygulayarak  $g_{best}^0$  bul //  $g_{best}$  minimum uygunluk değerine sahip
38     konuma göre başlat
39     while Iter ≤ Max_iteration yap (İterasyon sayısı tamamlanmadı)
40         for i = 1 to nPop yap
41             // Hızı güncelle
42              $r_1, r_2 \leftarrow [1, dim]$  aralığından rastgele üretilen iki bağımsız vektör
43             Denklem (25)'i uygulayarak parçacığın hızını güncelle
44             Denklem (26)'yı uygulayarak parçacığın konumunu güncelle
45             if  $f(x_i^t) < f(P_{best_i}^{t-1})$  ise
46                  $f(P_{best_i}^t) \leftarrow f(x_i^t)$ 
47             end if
48         end for
49         Atalet ağırlığını güncelle
50         İterasyonu güncelle
51     end while // PSO Optimizasyon Döngüsünün Sonu
52     bestSolution, bestFitness, iteration değerlerini döndür

```

2.3.2. Hibrit Güve-Alev Optimizasyonu-Salp Sürüsü Algoritması (MFO-SSA)

Önerilen çok aşamalı hibrit MFO-SSA algoritması, MFO ve SSA'yı birleştirir. Bu yaklaşım MFO ve SSA'yı sıralı olarak kullanır. İlk aşamada, ateşböceklerinin alevlere doğru spiral hareketinden esinlenen MFO, maksimum uygunluk değerlendirmelerinin yarısı (maxFEs/2) için optimizasyon algoritması olarak görev yapar. Bu aşama, MFO'nun basit yapısı, arama hızı ve güçlü keşif yeteneklerinden faydalanarak arama uzayının çeşitli bölgelerini etkili bir şekilde tarar, yerel optimumlarda takılmayı azaltırken diğer algoritmalarla kolay entegrasyon sağlar. İkinci aşamada ise, salpların çevrelerini keşfederken sergiledikleri zincir tabanlı sürü davranışını model alan SSA, kalan uygunluk değerlendirmelerini devralır. SSA, güçlü komşuluk arama özellikleri, basit uygulaması ve küresel optimum üretmedeki yüksek uygulanabilirlik ve verimlilik sayesinde umut verici

bölgelere odaklanarak çözümleri iyileştirir. MFO'nun küresel keşif gücünü SSA'nın yerel sömürme yetenekleriyle birleştirerek, MFO-SSA çok seviyeli eşikleme gibi problemlerin karmaşıklığına dinamik olarak uyum sağlar ve farklı yoğunluk dağılımlarına sahip görüntüler için uygun hale gelir. Çok aşamalı hibrit MFO-SSA algoritmasının akış şeması Şekil 2'de sunulmuş olup sözde kodu Algoritma 2'de verilmiştir.



Şekil 2. Çok aşamalı hibrit MFO-SSA algoritmasının akış şeması

Algoritma 2. MFO-SSA Algoritmasının Sözde Kodu

1	Girdi: Probleme özgü parametreler (p), Değişken sayısı (dim), Maksimum iterasyon sayısı (Max_iteration)
2	Çıktı: Bulunan en iyi çözüm (bestSolution), En iyi çözümün uygunluk değeri (bestFitness)
3	Başla
4	N, lb, ub, dim, Iter=1 parametrelerini başlat
5	// MFO Aşaması
6	Denklem (22) kullanarak alev sayısını (FlameNumber) güncelle
7	Moth konumlarını M'yi ve uygunluk değerlerini OM'yi başlat
8	Iter ≤ Max_iteration / 2 yap (İterasyon sayısının yarısına ulaşılmadı)
9	// Moth'ları sırala ve alevleri güncelle
10	if Iter == 1 ise
11	F = sort(M) ; // en iyi alevler

```


12         OF = sort(OM) ; // en iyi alev uygunluk
13     else
14         F = sort( $M_{t-1}$ ,  $M_T$ ) ; // önceki en iyi alevler
15         OF = sort( $M_{t-1}$ ,  $M_T$ ) ; // önceki en iyi alev uygunluk
16     end if
17     // Spiral hareket kullanarak moth konumlarını güncelle
18     for i = 1 to N yap
19         for j = 1 to dim yap
20             t ve a'yı güncelle (t, [a,1] aralığında rastgele bir sayıdır,
                burada a, iterasyon sürecinde -1'den -2'ye doğrusal olarak
                azalır)
21             İlgili moth'a göre Denklem (21) kullanarak D'yi hesapla
22             İlgili moth'a göre Denklem (19) ve (20) kullanarak M(i,j)
                matrisini güncelle
23         end for
24     end for
25     İterasyonu güncelle
26 end while // MFO Optimizasyon Döngüsünün Sonu
27 // SSA Aşaması
28 // MFO sonuçları ile Salp'leri başlat
29 SalpPositions = Moth_pos //MFO'dan elde edilen en iyi çözümler SSA aşamasına
    aktarılır
30 SalpFitness = Moth_fitness // MFO'dan elde edilen en iyi çözümler SSA aşamasına
    aktarılır
31 while Iter ≤ Max_iteration yap (İterasyon sayısı tamamlanmadı)
32     Denklem (32)'yi uygulayarak c1'i güncelle
33     for i = 1 to N yap
34         if i ≤ N / 2 ise
35             Lider Salp'leri Denklem (31)'i uygulayarak güncelle
36         Else
37             Takipçi Salp'leri Denklem (34)'ü uygulayarak güncelle
38         end if
39     end for
40     // Salp'lerin sınırlar içinde kalmasını sağla ve uygunluk değerlerini
        değerlendir
41     for i = 1 to N do
42         if SalpFitness(i) < FoodFitness ise
43             Besin kaynağını (en iyi çözüm) güncelle
44             Besin kaynağını (en iyi uygunluk) güncelle
45         end if
46     end for
47     İterasyonu güncelle
48 end while // SSA Optimizasyon Döngüsünün Sonu
49 bestSolution, bestFitness, iteration değerlerini döndür

```

2.3.3. Hibrit Güve-Alev Optimizasyonu-Parçacık Sürü Optimizasyonu-Salp Sürüsü Algoritması (MFO-PSO-SSA)

Önerilen çok aşamalı hibrit MFO-PSO-SSA algoritması, MFO, PSO ve SSA'nın güçlü yönlerini üç aşamalı bir optimizasyon çerçevesinde birleştirir. Tek bir meta sezgisel algoritmaya bağlı kalmak yerine, bu yaklaşım MFO, PSO ve SSA'yı sıralı olarak kullanır.

İlk aşamada, ateşböceklerinin alevlere doğru spiral hareketinden esinlenen MFO, maksimum uygunluk değerlendirmelerinin ilk üçte biri ($\max FEs/3$) için optimizasyon algoritması olarak görev yapar. Bu aşama, MFO'nun basit yapısı, hızlı arama hızı ve kolay entegrasyon yeteneği sayesinde çözüm uzayında güçlü keşif yetenekleri sunar. İkinci aşamada, sürüdeki parçacıkların sosyal davranışını model alan PSO, uygunluk değerlendirmelerinin bir sonraki üçte biri ($\max FEs/3$) için devreye girer. PSO basit uygulaması, az sayıda kontrol parametresi ve üstün yakınsama performansı ile umut verici bölgelerde çözümleri iyileştirir. Son olarak, salpların zincir tabanlı sürü davranışından esinlenen SSA, kalan uygunluk değerlendirmelerinde kullanılır. Güçlü komşuluk arama özellikleri, basit uygulanabilirliği ve küresel optimum üretmedeki yüksek verimlilikle yeni çözümleri keşfetmeye ve sömürmeye devam eder. MFO'nun keşif yeteneği, PSO'nun sömürü gücü ve SSA'nın iyileştirme özelliği birleştirilerek, MFO-PSO-SSA kapsamlı bir arama stratejisi kazanır ve segmentasyon doğruluğu, hesaplama verimliliği ve dayanıklılık açısından iyi bir performans gösterir. Bu çok aşamalı yaklaşım, ölçeklenebilirliği artırarak, eşik sayısı arttıkça önemli bir performans kaybı olmadan karmaşık çok seviyeli eşikleme problemlerini, farklı yoğunluk dağılımlarına veya birden fazla ilgi bölgesine sahip görüntüleri işlemek için ideal hale getirir. Çok aşamalı hibrit MFO-PSO-SSA algoritmasının akış şeması Şekil 3'te sunulmuş olup sözde kodu Algoritma 3'te verilmiştir.



Şekil 3. Çok aşamalı hibrit MFO-PSO-SSA algoritmasının akış şeması

 Algoritma 3. MFO-PSO-SSA Algoritmasının Sözde Kodu

```

1  Girdi: Probleme özgü parametreler (p), Değişken sayısı (dim), Maksimum
    iterasyon sayısı (Max_iteration)
2  Çıktı: Bulunan en iyi çözüm (bestSolution), En iyi çözümün uygunluk değeri
    (bestFitness)
3  Başla
4  N, lb, ub, dim, Iter=1 parametrelerini başlat
5  // MFO Aşaması
6  Denklem (22) kullanarak alev sayısını (FlameNumber) güncelle
7  Moth konumlarını M'i ve uygunluk değerlerini OM'yi başlat
8  while Iter ≤ Max_iteration / 3 yap (İterasyon sayısının üçte birine ulaşılmadı)
9      // Moth'ları sırala ve alevleri güncelle
10     if Iter == 1 ise
11         F = sort(M) ; // en iyi alevler
12         OF = sort(OM) ; // en iyi alev uygunluk
13     else
14         F = sort( $M_{t-1}, M_T$ ) ; // önceki en iyi alevler
15         OF = sort( $M_{t-1}, M_T$ ) ; // önceki en iyi alev uygunluk
16     end if
17     // Spiral hareket kullanarak moth konumlarını güncelle
18     for i = 1 to N yap
19         for j = 1 to dim yap
20             t ve a'yı güncelle (t, [a,1] aralığında rastgele bir sayıdır,
                burada a, iterasyon sürecinde -1'den -2'ye doğrusal olarak
                azalır)
21             İlgili moth'a göre Denklem (21) kullanarak D'yi hesapla
22             İlgili moth'a göre Denklem (19) ve (20) kullanarak M(i,j)
                matrisini güncelle
23         end for
24     end for
25     İterasyonu güncelle
26 end while // MFO Optimizasyon Döngüsünün Sonu
27 // PSO Aşaması
28 nPop, w, wdamp, c1, c2, VelMax, VelMin parametrelerini başlat
29 // Parçacıkları MFO sonuçları ile başlat
30 for i = 1 to nPop yap
31     // MFO'dan elde edilen en iyi çözümler, PSO aşamasına girdi olarak
        aktarılır
32     particle(i).Position = Moth_pos(i) // Parçacıkların konumlarını başlat
33     particle(i).Cost = Moth_fitness(i) // Parçacıkların hızını başlat
34      $P_{best}^0 \leftarrow x_i^0$  //  $P_{best}$  başlangıç konumuna göre başlat
35 end for
36 Denklem (24)'ü uygulayarak  $g_{best}^0$  bul //  $g_{best}$  minimum uygunluk değerine
    sahip konuma göre başlat
37 while Iter ≤ 2*Max_iteration/3 yap (İterasyon sayısının üçte ikisine ulaşılmadı)
38     for i = 1 to nPop do
39         // Hızı güncelle
40          $r_1, r_2 \leftarrow [1, dim]$  aralığından rastgele üretilen iki bağımsız vektör
41         Denklem (25)'i uygulayarak parçacığın hızını güncelle
42         Denklem (26)'yı uygulayarak parçacığın konumunu güncelle
43         if  $f(x_i^t) < f(P_{best_i}^{t-1})$  ise
44              $f(P_{best_i}^t) \leftarrow f(x_i^t)$ 
45         end if

```

```

46         end for
47         Atalet ağırlığını güncelle
48         İterasyonu güncelle
49     end while // PSO Optimizasyon Döngüsünün Sonu
50     // SSA Aşaması
51     // PSO sonuçları ile Salp'leri başlat
52     SalpPositions = Moth_pos           //MFO'dan elde edilen en iyi çözümler SSA
                                         aşamasına aktarılır
53     SalpFitness = Moth_fitness        // MFO'dan elde edilen en iyi çözümler SSA
                                         aşamasına aktarılır
54     while Iter ≤ Max_iteration yap (İterasyon sayısı tamamlanmadı)
55         Denklem (32)'yi uygulayarak c1'i güncelle
56         for i = 1 to N do
57             if i ≤ N / 2 ise
58                 Lider Salp'leri Denklem (31)'i uygulayarak güncelle
59             else
60                 Takipçi Salp'leri Denklem (34)'ü uygulayarak güncelle
61             end if
62         end for
63         // Salp'lerin sınırlar içinde kalmasını sağla ve uygunluk değerlerini
        değerlendir
64         for i = 1 to N do
65             if SalpFitness(i) < FoodFitness ise
66                 Besin kaynağını (en iyi çözüm) güncelle
67                 Besin kaynağını (en iyi uygunluk) güncelle
68             end if
69         end for
70         İterasyonu güncelle
71     end while // SSA Optimizasyon Döngüsünün Sonu
72     bestSolution, bestFitness, iteration değerlerini döndür

```

2.4. Önerilen Ağırlıklı Şempanze Optimizasyon Algoritması ile Uygunluk-Mesafe Dengesi (WChOA-UMD)

Meta sezgisel algoritmalar, geleneksel eşikleme yaklaşımlarının sınırlamalarını aşmak için çözüm sunar. Bu algoritmalar, doğal olaylardan veya sosyal davranışlardan esinlenen sezgisel arama yöntemleridir. Kesin optimizasyon tekniklerinin aksine, meta sezgisel algoritmalar küresel optimumu bulmayı garanti etmez ancak büyük ve karmaşık çözüm uzaylarını verimli bir şekilde keşfederek neredeyse optimum çözümleri belirlemede üstünlük gösterir. Her bir meta sezgisel algoritma türü, çözümleri oluşturma ve güncelleme süreçleri için kendi kurallarına sahiptir. Örneğin, genetik algoritmalar mevcut çözümlerin öğelerini birleştirerek yeni çözümler üretir ve bu süreçte doğal seleksiyon ve evrim süreçlerini taklit eder. Çözüm oluşturma ve güncelleme mekanizmalarındaki bu çeşitlilik, farklı meta sezgisel algoritmaların aynı problem üzerinde uygulandığında değişken sonuçlar üretmesine neden olabilir. Bu değişkenlik, araştırmacıların ve uygulamacıların birden fazla

yaklaşımı deneyerek belirli ihtiyaçları için en etkili yöntemi belirlemelerine olanak sağladığından avantajlıdır.

Bu bölümde, WChOA-UMD (Ağırlıklı Şempanze Optimizasyon Algoritması ile Uygunluk-Mesafe Dengesi) adında yeni bir meta sezgisel algoritma tanıtılmaktadır. Bu algoritmanın prensipleri, mekanizmaları ve özellikleri detaylı bir şekilde incelenerek, optimizasyon görevlerindeki işleyişini ve potansiyel uygulamalarını tam anlamıyla kavramak hedeflenmektedir. Bu bölümde önce WChOA algoritması'nın genel bir özeti verilmiştir. Ardından, çok seviyeli eşikleme ve diğer optimizasyon zorluklarında performansı artırmak için UMD (uygunluk-mesafe dengesi) yaklaşımını içeren karma strateji mekanizmasını birleştiren önerilen WChOA-UMD algoritması açıklanmıştır.

2.4.1. Ağırlıklı Şempanze Optimizasyon Algoritması (WChOA)

Geliştirilen orijinal Şempanze Optimizasyon Algoritması (ChOA) (Khishe & Mosavi, 2020)'nın geliştirilmiş bir versiyonu olan Ağırlıklı Şempanze Optimizasyon Algoritması (WChOA)'yı tanıtmışlardır (Khishe, vd., 2021). ChOA, vahşi doğadaki şempanzelerin avlanma davranışını taklit eden meta sezgisel bir algoritmadır. Diğer doğadan ilham alan optimizasyon yöntemleriyle karşılaştırıldığında, ChOA parametre ayarlamasının minimum düzeyde olması ve nispeten kolay uygulanabilir olması açısından dikkat çekicidir. Algoritma, bir kolonideki dört farklı şempanze tipinin rollerini modellemektedir: sürücü, bariyer, kovalayıcı ve saldırgan. Bu roller, avlanma sürecinde belirli sorumluluklar üstlenerek arama işlemini en iyi çözüme doğru yönlendirmeyi hedefler ve keşif (yeni bölgeleri araştırma) ile sömürü (mevcut çözümleri iyileştirme) arasında denge kurmayı amaçlar.

Geleneksel ChOA'da, diğer tüm şempanzelerin konumları yalnızca başlangıçtaki dört en iyi çözüme göre güncellenir. Esasen, kalan şempanzeler bu dört öncü çözümün etrafında toplanır ve bu çözümler arama uzayının en umut verici bölgelerini temsil eder. Ancak, bu yaklaşımın bazı doğal sınırlamaları bulunmaktadır. Örneğin, saldırganlar avın hareketini tahmin etmekle sorumlu olsa da, her zaman optimum çözümleri garanti edemez. Bu belirsizlik, şempanzelerin avlanma sürecinde belirlenen rollerinden sapabilmeleri veya bir görev üzerinde aşırı odaklanmaya devam etmelerinden kaynaklanmaktadır. Sonuç olarak, yalnızca saldırganın çözümüne güvenmek erken yakınsamaya yol açabilir ve aramayı yerel optimumlarda hapseder, ayrıca henüz keşfedilmemiş bölgelerin araştırılmasını kısıtlayabilir.

Benzer endişeler diğer ana roller (sürücü, kovalayıcı ve bariyer) için de geçerlidir, çünkü bu rollerin etkisi aramayı alt optimum çözümlerin etrafında yoğunlaştırabilir.

Bu zorlukları ele almak için, WChOA, ChOA'nın iyileştirilmiş bir versiyonu olarak geliştirilmiştir. WChOA, adım boyutunun Öklid mesafesine dayalı ağırlıkları içeren bir konum-ağırlıklı denklem tanıtır. Bu değişiklik, kalan şempanzelerin konumlarının daha etkili bir şekilde güncellenmesini sağlayarak hem keşfi hem de sömürüyü güçlendirir. Özellikle, önerilen ağırlıklandırma mekanizması, herhangi bir tek role (örneğin, saldırgan) aşırı bağımlılık riskini azaltır ve daha dengeli bir arama stratejisi teşvik eder. Şempanzelerin güncellenen konumları, Denklem (38), (39) ve (40) kullanılarak belirlenir; bu denklemler, kalan şempanzelerin sürücü, kovalayıcı, saldırgan ve bariyere göre konumlarını ayarlamasını sağlar.

$$\vec{D}_{\text{Attacker}} = |\vec{C}_1 \vec{X}_{\text{Attacker}} - \vec{M}_1 \vec{X}| \quad \vec{D}_{\text{Barrier}} = |\vec{C}_2 \vec{X}_{\text{Barrier}} - \vec{M}_2 \vec{X}| \quad (21)$$

$$\vec{D}_{\text{Chaser}} = |\vec{C}_3 \vec{X}_{\text{Chaser}} - \vec{M}_3 \vec{X}| \quad \vec{D}_{\text{Driver}} = |\vec{C}_4 \vec{X}_{\text{Driver}} - \vec{M}_4 \vec{X}|$$

$$\vec{X}_1 = \vec{X}_{\text{Attacker}} - \vec{A}_1(\vec{D}_A) \quad \vec{X}_2 = \vec{X}_{\text{Barrier}} - \vec{A}_2(\vec{D}_B) \quad (22)$$

$$\vec{X}_3 = \vec{X}_{\text{Chaser}} - \vec{A}_3(\vec{D}_C) \quad \vec{X}_4 = \vec{X}_{\text{Driver}} - \vec{A}_4(\vec{D}_D)$$

Vektörler $\vec{X}_{\text{Attacker}}$, $\vec{X}_{\text{Barrier}}$, $\vec{X}_{\text{Chaser}}$ and $\vec{X}_{\text{Driver}}$ sırasıyla saldırgan, bariyer, kovalayıcı ve sürücü şempanzelerin mevcut konumlarını temsil eder. Vektör $\vec{X}$, popülasyondaki diğer şempanzelerin mevcut konumunu ifade eder. Ayrıca, $\vec{C}$, $\vec{M}$ ve $\vec{A}$ vektörleri ChOA için önemli bir rol oynar. Bu vektörler, Denklem (40) ile (42) kullanılarak hesaplanır:

$$\vec{A} = 2.f.\vec{r}_1 - f \quad (23)$$

$$\vec{C} = 2.\vec{r}_2 \quad (24)$$

$$\vec{M} = \text{Chaotic_value} \quad (25)$$

Burada, $\vec{r}_1$ ve $\vec{r}_2$, $[0, 1]$ aralığında değer alan rastgele vektörlerdir. f ise optimizasyon süreci boyunca 2.5'ten 0'a kadar nonlineer olarak azalan bir kontrol parametresidir. ChOA'da cinsel motivasyonu modelleyen kaotik vektör $\vec{M}$, bir kaotik harita kullanılarak hesaplanır (Khishe, vd., 2021). Kaotik davranışın bu entegrasyonu, özellikle yüksek boyutlu problemler

ele alındığında, yerel optimumlarda sıkışma ve yavaş yakınsama hızı gibi zorlukların üstesinden gelme yeteneğini artırır.

Bunu uygulamak için çalışmada altı farklı kaotik harita (Chebyshev haritası, Circle haritası, Gauss/fare haritası, İteratif harita, Lojistik harita ve Parçalı harita) kullanılmıştır. Bu kaotik haritalar, deterministik süreçler olup görünürde rastgele davranış sergilemekte ve algoritmanın keşif ile sömürü arasında denge kurmasını sağlayarak genel verimliliğini artırmaktadır.

$$w_1 = \frac{|\vec{X}_1|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3| + |\vec{X}_4|} \quad (26)$$

$$w_2 = \frac{|\vec{X}_2|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3| + |\vec{X}_4|} \quad (27)$$

$$w_3 = \frac{|\vec{X}_3|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3| + |\vec{X}_4|} \quad (28)$$

$$w_4 = \frac{|\vec{X}_4|}{|\vec{X}_1| + |\vec{X}_2| + |\vec{X}_3| + |\vec{X}_4|} \quad (29)$$

Burada, w_1 , w_2 , w_3 ve w_4 , sırasıyla diğer şempanzelerin saldırgan, bariyer, kovalayıcı ve sürücüyü göre öğrenme oranlarını temsil eder. Ayrıca, $|\cdot|$, arama uzayındaki konumlar arasındaki uzamsal ayrımı ölçen Öklid mesafesini ifade eder. Orijinal ChOA'da, şempanzelerin konumları arasındaki ilişki aşağıdaki denklemle hesaplanır:

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3 + \vec{X}_4}{4} \quad (30)$$

Ancak, WChOA'da konum-ağırlıklı ilişki Denklem 48 kullanılarak hesaplanır:

$$\vec{X}(t+1) = \frac{1}{w_1 + w_2 + w_3 + w_4} \times \frac{w_1 \vec{X}_1 + w_2 \vec{X}_2 + w_3 \vec{X}_3 + w_4 \vec{X}_4}{4} \quad (31)$$

WChOA'da, Denklem (48)'de tanımlanan konum-ağırlıklı ilişki, standart ChOA'daki Denklem (47)'nin bir alternatifi olarak kullanılabilir. Denklem (48) ile geleneksel konum-ağırlıklı ilişki olan Denklem (47) arasındaki temel fark, ilgili öğrenme oranlarının dahil

edilmesidir. Daha önce de tartışıldığı gibi, avlanma sürecinde bazı şempanzelerin cinsel motivasyonu olmayabileceğinden, şempanzelerin konum-ağırlıklı stratejisinin normal model Denklem (48)'i mi yoksa kaotik bir modeli mi izleyeceği belirlenirken %50'lik bir olasılık değeri tanıtılmıştır. Bu olasılıksal değerlendirmeye dayanarak, aşağıdaki ilişki uygulanır:

$$\overrightarrow{X_{chump}}(t + 1) = \begin{cases} Eq. (48) & \text{if } \mu < 0,5 \\ \text{Chaotic - Value} & \text{if } \mu \geq 0,5 \end{cases} \quad (32)$$

Burada, t , mevcut iterasyonu, μ şempanzelerin konum-ağırlıklı stratejisini belirleyen $[0, 1]$ aralığında bir olasılık değeri temsil eder.

Konum-ağırlıklı ilişkideki öğrenme oranlarının dinamik olduğu ve WChOA'nın iterasyonları boyunca değiştiği unutulmamalıdır. Bu parametreler sabit değildir ve bu da optimizasyon sürecinde uyarlanabilir ayarlamalara olanak tanır. Bu dinamik davranış, yakınsama hızını artırır ve algoritmanın yerel optimumlardan kaçınma yeteneğini güçlendirir. Özellikle, saldırgan, bariyer, kovalayıcı ve sürücülerin avın konumu hakkında kesin bilgi sahibi olma olasılığını azaltır; böylece keşfi teşvik eder ve arama sürecinde çeşitliliği korur.

2.4.2. Uygunluk-Mesafe Dengesi (UMD)

UMD seçme yöntemi (Kahraman, Aras, & Gedikli, 2020), popülasyon tabanlı ve evrimsel MSA'larda kullanılan önemli bir tekniktir. Bu yöntem, aday çözümleri iki kritik faktöre göre değerlendirerek seçim sürecini yönlendirir: uygunluk değerleri ve optimal çözümden uzaklıkları. Normalleştirilmiş uygunluk ve mesafe metrikleri kullanılarak her aday için UMD puanları hesaplanır ve bu yöntem, yüksek kaliteli çözümlerin seçilmesi ile popülasyon içinde çeşitliliğin korunması arasındaki dengeyi etkili bir şekilde sağlar. Bu denge, algoritmanın çözüm uzayının çeşitli bölgelerini keşfetmesini sağlayarak birden fazla optimumu bulma yeteneğini artırır. Sonuç olarak, UMD seçme yöntemi, MSA'ların karmaşık arama uzaylarında daha etkili gezinmesini sağlayarak verimlilik ve etkinliğini artırır. Bu, yüksek UMD puanlarına sahip adayları önceliklendirerek ve bunları popülasyonun yakınsamaya doğru yönlendirmede uygun seçenekler olarak kabul ederek başarılıdır (Orujpour, Feizi-Derakhshi, & Akan, 2023). UMD sürecinin ilk aşamasında, popülasyonun en iyi bireyden uzaklığı Denklem (50) kullanılarak hesaplanır.

$$_{i=1}^n \forall P_i \neq P_{best}, D_i = \sqrt{\sum_{j=1}^d (x_{jbest} - x_{ji})^2} \quad (33)$$

Denklem (50)'de, P , çözüm kümesini temsil eder, n , P içindeki çözüm vektörlerinin sayısını ifade eder ve D , mesafe vektörünü gösterir. Burada, x_{best} ve x_i , sırasıyla en iyi çözümün ve i . çözümün çözüm vektörlerine karşılık gelir. d parametresi ise optimizasyon problemindeki değişken sayısı olan problem boyutunu temsil eder. Çözüm adaylarının puanlarını değerlendirmek için normalleştirilmiş uygunluk değerleri ($normF$) ve normalleştirilmiş mesafe değerleri ($normD$) kullanılır. Her iki parametreye de normalizasyon uygulanarak aralarında bir üstünlük kurulması engellenir. Daha sonra her bir aday için UMD puanı, Denklem (51) kullanılarak hesaplanır:

$$_{i=1}^n \forall P_i, UMD_Score_{P_i} = w \times normF_i + (1 - w) \times normD_{P_{best_i}} \quad (34)$$

Denklemde $normD_{P_{best_i}}$, P içindeki i . çözüm adayının P_{best} 'e olan normalleştirilmiş mesafesini ifade eder; burada P_{best} , P içindeki en iyi uygunluk değerine sahip çözümdür. Ağırlık katsayısı (w), çözüm vektörlerinin puanlarını hesaplarken uygunluk ve mesafe değerlerinin etkisini dengelemek için kullanılır. w değeri, $0 < w < 1$ aralığında olup uygunluk ile çeşitlilik arasında bir denge sağlar. Bu tanımlara dayanarak, popülasyon P içindeki her bir adayın skoru belirlenir.

2.4.3. Ağırlıklı Şempanze Optimizasyon Algoritması ile Uygunluk-Mesafe Dengesi (WChOA-UMD)

Meta sezgisel algoritmaların arama yetenekleri, büyük ölçüde yakınsama denklemlerinin tasarımına bağlıdır; bu denklemler, çözüm adaylarının arama uzayındaki konumlarını belirler. Bu adayların hareketi, keşif ve sömürü arasında bir denge sağlamayı amaçlayan popülasyonun yönünü ve davranışını etkileyen yakınsama denklemlerine gömülü olan özel mekanizmalar tarafından yönlendirilir. Popülasyondan rastgele seçilen rehberler, henüz keşfedilmemiş bölgelerin araştırılmasını teşvik ederek çeşitlilik etkisi yaratırken, aç gözlü yöntem kullanılarak seçilen rehberler, bilinen en iyi çözümlere yakın umut verici bölgelere odaklanarak sömürüyü artırır. UMD seçme yöntemi, çözüm adaylarını iki temel

faktöre göre değerlendirir: uygunluk değerleri ve popülasyondaki en iyi bireye olan uzaklıkları. Uygunluk değeri, bir adayın çözüm kalitesi açısından ne kadar iyi performans gösterdiğini yansıtan sömürü etkisini ifade ederken, uzaklık değeri çeşitlilik etkisini yansıtır ve adayların erken yakınsamayı önlemek için arama uzayında dağılmış olmasını sağlar. Hem uygunluk hem de uzaklık dikkate alınarak, UMD seçme yöntemi keşif ve sömürü arasında optimal bir denge sağlayan rehberleri etkili bir şekilde belirler; bu da onu meta sezgisel algoritmaların arama yeteneklerini artırmak için güçlü bir araç haline getirir. Önceki çalışmalar, çeşitli meta sezgisel arama algoritmalarının rehberlik mekanizmalarının UMD seçme yöntemi kullanılarak yeniden tasarlandığında performanslarında önemli iyileşmeler elde edildiğini göstermiştir (kaynak). Bu tezde, UMD seçme yöntemi, WChOA algoritmasının rehberlik mekanizmasını geliştirmek için uygulanmıştır. Bu sayede, keşif ve sömürü arasında denge kurabilen çözüm adaylarının WChOA'nın yakınsama denklemlerinde rehber olarak kullanılması sağlanmıştır. Bu iyileştirme, algoritmanın arama uzayında etkin bir şekilde gezinmesini sağlar; böylece yerel optimumlardan kaçınırken yüksek kaliteli çözümleri bulma yeteneğini artırır. Önerilen yöntemin detaylı algoritmik süreçleri aşağıda açıklanmıştır:

1. UMD Parametreleri ile Başlatma: WChOA-UMD, UMD'ye özgü parametreleri içeren potansiyel çözümlerden oluşan bir popülasyon başlatarak işe başlar.
2. UMD ile Ağırlıklı Çözüm Değerlendirme: UMD tarafından güçlendirilen ağırlıklı değerlendirme mekanizması, çözümlere hem uygunluk değerlerine hem de mesafelerine göre ağırlık atar. Bu ağırlıklı yaklaşım, sonraki karar alma süreçlerini yönlendirir.
3. UMD ile Güçlendirilmiş İşbirlikçi Karar Alma: Çözümler, UMD rehberliğiyle güçlendirilmiş şekilde işbirlikçi karar alma sürecine girer. Algoritma, çözümleri yalnızca uygunluk değerlerine göre değil, aynı zamanda popülasyon içinde çeşitliliği korumaya olan katkılarına göre önceliklendirir.
4. UMD ile Dinamik Adaptasyon: WChOA-UMD, optimizasyon süreci boyunca UMD etkisiyle parametrelerini dinamik olarak uyarlar. Bu, sürekli ve uyarlanabilir bir keşif-sömürü dengesi sağlar.
5. UMD ile Güçlendirilmiş Yinelemeli Optimizasyon: Algoritma, entegre edilen UMD ilkelerinden yararlanarak çözümleri yinelemeli olarak optimize eder ve keşif ile sömürü arasında denge kurar.

UMD tabanlı WChOA varyantları (Durum-1, Durum-2, Durum-3, Durum-4, Durum-5, Durum-6, Durum-7 ve Durum-8), WChOA algoritmasının keşif yeteneğini ve dengeli arama kabiliyetini artırmak amacıyla geliştirilmiştir.

Tablo 2. WChOA- UMD varyantlarının matematiksel modeli

Algoritma	Açıklama	Matematiksel Model
Durum-1	Sürücü denklemindeki $\vec{X}_{Driver}$ bileşeninin UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{FDB} - \vec{M}_4 \vec{X} $ (52)
Durum-2	Sürücü denklemindeki $\vec{X}$ bileşeninin UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{Driver} - \vec{M}_4 \vec{X}_{FDB} $ (53)
Durum-3	Saldırgan ve Sürücü denklemlerindeki $\vec{X}_{Attacker}$ ve $\vec{X}_{Driver}$ bileşenlerinin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Attacker} = \vec{C}_1 \vec{X}_{FDB} - \vec{M}_1 \vec{X} $ $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{FDB} - \vec{M}_4 \vec{X} $ (54)
Durum-4	Saldırgan ve Sürücü denklemlerindeki $\vec{X}_{Attacker}$ ve $\vec{X}$ bileşenlerinin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Attacker} = \vec{C}_1 \vec{X}_{FDB} - \vec{M}_1 \vec{X} $ (55) $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{Driver} - \vec{M}_4 \vec{X}_{FDB} $
Durum-5	Saldırgan ve Sürücü denklemlerindeki $\vec{X}$ ve $\vec{X}_{Driver}$ bileşenlerinin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Attacker} = \vec{C}_1 \vec{X}_{Attacker} - \vec{M}_1 \vec{X}_{FDB} $ (56) $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{FDB} - \vec{M}_4 \vec{X} $
Durum-6	Saldırgan ve Sürücü denklemlerindeki $\vec{X}$ bileşeninin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Attacker} = \vec{C}_1 \vec{X}_{Attacker} - \vec{M}_1 \vec{X}_{FDB} $ $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{Driver} - \vec{M}_4 \vec{X}_{FDB} $ (57)
Durum-7	Bariyer ve Sürücü denklemlerindeki $\vec{X}_{Barrier}$ ve $\vec{X}_{Driver}$ bileşenlerinin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Barrier} = \vec{C}_2 \vec{X}_{FDB} - \vec{M}_2 \vec{X} $ $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{FDB} - \vec{M}_4 \vec{X} $ (58)
Durum-8	Bariyer ve Sürücü denklemlerindeki $\vec{X}$ ve $\vec{X}_{Driver}$ bileşenlerinin sırasıyla UMD yöntemi ($\vec{X}_{FDB}$) ile değiştirilmesi	$\vec{D}_{Barrier} = \vec{C}_2 \vec{X}_{Barrier} - \vec{M}_2 \vec{X}_{FDB} $ $\vec{D}_{Driver} = \vec{C}_4 \vec{X}_{FDB} - \vec{M}_4 \vec{X} $ (59)

UMD yönteminin uygulandığı denklemler ve WChOA-UMD varyantlarının matematiksel modelleri Tablo 2’de verilmiştir. Ayrıca, önerilen WChOA-UMD

algoritmasının genel çerçevesi ve UMD seçme yönteminin uygulandığı denklemler, Algoritma 4'te adım adım açıklanmıştır.

Algoritma 4. Önerilen WChOA-UMD algoritmasının sözde kodu

```

1.  Girdi: Şempanze popülasyonu ( $p$ ), İterasyon sayısı (Max_iter), Problem boyutu (değişken sayısı) ( $d$ )
2.  Çıktı:  $X_{Attacker}$ 
3.  Başla:
4.   $f$ ,  $m$ ,  $a$  ve  $c$  sabitlerini başlat
5.  Her şempanze için başlangıç konumlarını (popülasyon) hesapla ve uygunluk değerlerini değerlendir
6.  Şempanzeleri rastgele ayrı gruplara böl
7.  for  $i=1$ :  $p$  yap
8.      Her şempanzenin uygunluğunu değerlendir
9.  end for
10.  $x_{attacker}$  = en iyi arama ajanı
11.  $x_{barrier}$  = ikinci en iyi arama ajanı
12.  $x_{chaser}$  = üçüncü en iyi arama ajanı
13.  $x_{driver}$  = dördüncü en iyi arama ajanı
14. // Meta-sezgisel arama süreci //
15. while ( $l < \text{Max\_iter}$ ) // (İterasyon sayısı tamamlanmadı)
16.     for  $i=1$ :  $p$  yap
17.         Her şempanze için:
18.             Şempanzenin grubunu belirle
19.             Grup stratejisini kullanarak  $f$ ,  $m$  ve  $c$ 'yi güncelle
20.              $f$ ,  $m$  ve  $c$ 'yi kullanarak  $a$ 'yı hesapla, ardından  $d$ 'yi hesapla
21.         end for
22.     // UMD seçim yönteminin uygulanması //
23.     for  $i=1$ :  $p$  yap
24.         Her şempanze için Denklem (50) kullanarak Öklid mesafesini hesapla
25.         Her şempanze için Denklem (51) kullanarak UMD skorunu hesapla
26.     end for
27.     Denklem (50) ve Denklem (51) kullanarak D ve S vektörlerini oluştur
28.     UMD felsefesini kullanarak Denklem (38) ile  $X_{FDB}$ 'yi belirle
29.     Denklem (52) kullanarak  $d\_Driver$  hesapla // Durum-1 //
30.     Denklem (53) kullanarak  $d\_Driver$  hesapla // Durum-2 //
31.     Denklem (54) kullanarak  $d\_Attacker$  ve  $d\_Driver$  hesapla // Durum-3 //
32.     Denklem (55) kullanarak  $d\_Attacker$  ve  $d\_Driver$  hesapla // Durum-4 //
33.     Denklem (56) kullanarak  $d\_Attacker$  ve  $d\_Driver$  hesapla // Durum-5 //
34.     Denklem (57) kullanarak  $d\_Attacker$  ve  $d\_Driver$  hesapla // Durum-6 //

```

```

35.         Denklem (58) kullanarak d_Barrier ve d_Driver hesapla // Durum-7 //
36.         Denklem (59) kullanarak d_Barrier ve d_Driver hesapla // Durum-8 //
37.         Denklem (38) kullanarak d_Chaser hesapla
38.     end for
39.     for i=1: p do
40.         if ( $\varphi < 0.5$ )
41.             if ( $|a| < 1$ )
42.                 Denklem (48) ile driver konumunu güncelle // Durum-1 //
43.                 Denklem (48) ile driver konumunu güncelle // Durum-2 //
44.                 Denklem (48) ile attacker ve driver konumlarını güncelle // Durum-3 //
45.                 Denklem (48) ile attacker ve driver konumlarını güncelle // Durum-4 //
46.                 Denklem (48) ile attacker ve driver konumlarını güncelle // Durum-5 //
47.                 Denklem (48) ile attacker ve driver konumlarını güncelle // Durum-6 //
48.                 Denklem (48) ile barrier ve driver konumlarını güncelle // Durum-7 //
49.                 Denklem (48) ile barrier ve driver konumlarını güncelle // Durum-8 //
50.                 Denklem (48) ile chaser konumunu güncelle
51.             else if ( $|a| > 1$ )
52.                 Rastgele bir arama ajanı seç
53.             end if
54.         else if ( $\varphi > 0.5$ )
55.             Denklem (49) kullanarak mevcut arama ajanının konumunu güncelle
56.         end if
57.     end for
58.     Sabitleri  $f$ ,  $m$ ,  $a$  ve  $c$ 'yi güncelle
59.      $X_{Attacker}$ ,  $x_{barrier}$ ,  $x_{chaser}$  ve  $x_{driver}$ 'ı güncelle
60. end while
61.  $X_{Attacker}$ 'i döndür

```

2.4.4. Hesaplama Karmaşıklığı

WChOA algoritmasının hesaplama karmaşıklığı, üç temel faktöre bağlıdır: şempanze sayısı (n), iterasyon sayısı ($maxFEs$) ve her iterasyonda kullanılan sıralama yöntemi (Khishe, vd., 2021). Her iterasyon sırasında, algoritma ilk dört en iyi çözümü belirler ve bunlara sürücü, kovalayıcı, saldırgan ve bariyer rollerini atar. Sıralama işlemi, en iyi durumda $O(n \times \log n)$ ve en kötü durumda $O(n^2)$ karmaşıklığa sahip olan Hızlı Sıralama (Quick Sor) yöntemini kullanır. Buna dayanarak, WChOA'nın genel hesaplama karmaşıklığı şu şekilde ifade edilir:

$$\begin{aligned}
O(WChOA) &= O(maxFes \times (O(quick\ sort) + O(position\ update))) \\
&= (maxFes \times (n^2 + n \times d))
\end{aligned} \tag{35}$$

Önerilen WChOA-UMD algoritması için, her bir şempanze için Öklid mesafelerini ve UMD puanlarını hesaplamak amacıyla Denklem (50) ve (51) kullanılarak ek hesaplamalar yapılır. Bu hesaplamalar, hesaplama yüküne katkıda bulunur. Sonuç olarak, WChOA-UMD'nin hesaplama karmaşıklığı şu şekilde tanımlanır:

$$\begin{aligned}
(WChOA - FDB) &= O(maxFes \times (O(quick\ sort) + O(FDB\ calculation) + \\
&\quad O(position\ update))) \\
&= (maxFes \times (n^2 + n \times d + n))
\end{aligned} \tag{61}$$

UMD puanı hesaplamaları için gereken ek hesaplamalara rağmen, WChOA-UMD'nin genel karmaşıklığı orijinal WChOA gibi hala karesel, yani $O(n \times d + n)$ düzeyindedir. Bu durum, algoritmanın UMD mekanizması tarafından sağlanan gelişmiş keşif ve sömürü yeteneklerini bünyesine katarak ölçeklenebilirliğini koruduğunu garanti eder.

3. BULGULAR VE TARTIŞMA

3.1. Deneyisel Ayarlar

Bu tezde, hem çok seviyeli eşikleme tabanlı görüntü segmentasyonu için önerilen çok aşamalı hibrit algoritmaların (MFO-PSO, MFO-SSA, MFO-PSO-SSA) hem de önerilen WChOA-UMD algoritmasının performansları değerlendirilmiştir. Çok seviyeli eşikleme tabanlı görüntü segmentasyonunda yaygın olarak kullanılan metasezgisel algoritmaların (ABC, CS, DE, GWO, HHO, MFO, PSO, SCA, SOS, SSA ve WOA) etkinlikleri karşılaştırılmıştır. Adil bir karşılaştırma sağlamak amacıyla durdurma kriteri, maksimum amaç fonksiyonu değerlendirme sayısı olarak belirlenmiş olup bu değer maxFEs ile temsil edilmiştir. Toplamda 100×3 optimizasyon problemi (her bir görüntü ve üç renk kanalının ayrı ayrı optimizasyon görevleri olarak değerlendirildiği) $\text{maxFEs} = 500 \times m$ ile yürütülmüştür. Her bir algoritma, her problem için 25 kez çalıştırılmıştır. Segmentasyon işlemi, düşükten orta seviyeye kadar olan eşikleme performanslarını analiz etmek amacıyla $m = 2, 3, 4, 5, 6, 7$ ve 8 eşik seviyelerinde test edilmiştir. Toplamda 11 farklı MSA, 100 görüntü üzerinde test edilmiş ve her bir görüntü, 3 renk kanalı ve 7 farklı eşik seviyesi kullanılarak Kapur entropisi amaç fonksiyonu ile değerlendirilmiştir. Bu, toplamda 23.100 deneye karşılık gelmektedir. Elde edilen sonuçlar Friedman istatistiksel testi kullanılarak analiz edilmiştir. Tüm MSA'ların orijinal parametre ayarları, Tablo 3'te belirtildiği şekilde kullanılmıştır.

Öte yandan, WChOA-UMD algoritmasının değerlendirmesi için:

- Önerilen algoritmanın performansını incelemek için dört farklı türde problem içeren IEEE CEC 2020 seti (Yue, vd., 2020) kullanılmıştır.
- Optimizasyon sürecinin sonlandırma kriteri, maksimum amaç fonksiyonu değerlendirme sayısı (maxFEs) ile belirlenmiştir. Bu kriter, $\text{maxFEs} = 1000 \times D$ olarak ayarlanmıştır; burada D, problem boyutunu temsil etmektedir.
- Algoritmanın düşük, orta ve yüksek boyutlu optimizasyon senaryolarındaki performansını analiz etmek ve değerlendirmek için deneyler, dört farklı problem boyutu ($D = 10, D = 30, D = 50$ ve $D = 100$) için bağımsız olarak yürütülmüştür.
- Her bir problem için optimizasyon işlemi 25 kez tekrarlanmıştır.

- Deneysel çalışmalardan elde edilen verileri analiz etmek amacıyla istatistiksel test yöntemleri kullanılmıştır.
- İkili karşılaştırmalar Wilcoxon testi ile gerçekleştirilirken, çoklu karşılaştırmalar Friedman testi kullanılarak yapılmıştır.

Tüm deneyler, Windows 11 işletim sistemi, Core i7 1065G7 1.30 GHz işlemci ve 12 GB RAM'e sahip bir bilgisayarda MATLAB R2018b ortamında gerçekleştirilmiştir.


Tablo 3. MSA ayarları

Algoritma	Ayarlar
ABC	koloni boyutu = 50, SN = koloni boyutu / 2, limit = D * SN
CS	yuva sayısı = 25, olasılık = 0.25, beta = 1.5
DE	popülasyon = 50, çaprazlama olasılığı = 0.2
GWO	arama ajanı sayısı = 30
HHO	N = 30, Bfid = 1, nD = 10, Jr = 0.25
MFO	moth sayısı = 30
PSO	sürü boyutu = 30, bilişsel ve sosyal sabit = 2
SCA	arama ajanı sayısı = 30, a = 2
SOS	Ekosistem boyutu = 50
SSA	salp popülasyon boyutu = 30
WOA	salp popülasyon boyutu = 30

3.2. Önerilen Çok Aşamalı Hibrit Algoritmaların Deneysel Bulguları

3.2.1. Veri Seti

Berkeley görüntü segmentasyonu veri seti (BSD300, n.d.), 300 görüntüden oluşan açık erişimli bir veri setidir; bu görüntülerin 200'ü eğitim, 100'ü ise test için ayrılmıştır. Veri seti hem gri tonlamalı hem de renkli görüntüler içermekte olup, doğal sahnelerden nesne-özel kategorilere (bitkiler, insanlar ve yiyecekler gibi) kadar geniş bir yelpazede yer alan görüntüler nedeniyle sıklıkla segmentasyon çalışmalarında kullanılmaktadır. Bu çalışmada, BSD300 içerisinde 100 renkli görüntüden oluşan BSD100 alt kümesi seçilerek çok seviyeli görüntü segmentasyonunda MSA'ların performansını değerlendirmek amacıyla kullanılmıştır. Şekil 4, BSD100'den rastgele seçilmiş görüntüler ile histogramlarını göstermektedir. Şekilden de görüleceği üzere görüntülerin parlaklık ve renk dağılımları oldukça çeşitlilik göstermekte olup bu durum, segmentasyon işleminin hesaplama karmaşıklığına ve çeşitliliğine katkı sağlamaktadır.



Şekil 4. Berkeley veri setinden örnek görüntüler ve histogramları (soldan sağa: '102061.jpg', '208001.jpg', '55073.jpg', '126007.jpg', '299086.jpg', '86068.jpg')

3.2.2. MSA'lar İçin İstatistiksel Analiz

Friedman testi, birden fazla deneysel deneme arasında farklılıkları belirlemek için kullanılan parametrik olmayan bir istatistiksel tekniktir. Aynı konulardan farklı algoritmalar, teknikler veya koşullar kullanılarak tekrarlanan ölçümler toplandığında özellikle değerlidir. Bu araştırma, 100 görüntüye 25 iterasyon boyunca uygulanan 11 algoritmanın istatistiksel değerlendirmesini içerir. Görüntüler renkli olduğu için R, G ve B kanalları için ayrı çözümler

hesaplanmış ve ardından ortalamaları belirlenmiştir. Deneysel sonuçlar, $m = 2, 3, 4, 5, 6, 7$ ve 8 eşik seviyelerinde segmentasyon için Kapur entropisi kullanılarak elde edilmiş olup, durdurma koşulu $maxFEs = 500 \times m$ olarak belirlenmiştir ve bu sonuçlar Tablo 4'te gösterilmiştir. Tablo 4'ün analizi, MFO algoritmasının tüm eşik seviyelerinde diğer algoritmalara göre daha başarılı olduğunu ortaya koymaktadır. MFO'yu, tüm eşiklerde ikinci sırada yer alan PSO algoritması takip etmektedir. PSO'nun ardından ABC, GWO ve SSA algoritmaları dikkate değer performans göstermekle birlikte sıralamaları eşik sayısına bağlı olarak değişmektedir. Örneğin, SSA, $m = 2, 3, 4$ ve 5 için üçüncü sırada yer alırken, $m = 7$ ve 8'de beşinci sıraya gerilemekte ve yerini ABC almaktadır. $m = 2$ eşik dışında, GWO, dördüncü sırayı korumaktadır. Buna karşılık, DE, SOS ve SCA algoritmaları bu değerlendirmede diğerlerine kıyasla en düşük performansı gösterenler olarak öne çıkmaktadır.

Tablo 4. MSA'lar için friedman puanları ve sıralamaları

m=2		m=3		m=4		m=5		m=6		m=7		m=8	
MFO	3,59	MFO	2,55	MFO	2,44	MFO	2,52	MFO	2,59	MFO	2,63	MFO	2,76
PSO	3,69	PSO	2,80	PSO	2,83	PSO	2,90	PSO	2,91	PSO	2,82	PSO	2,85
SSA	4,34	SSA	3,96	SSA	4,24	SSA	4,35	GWO	4,41	ABC	4,32	ABC	4,13
ABC	4,36	GWO	4,52	GWO	4,45	GWO	4,46	ABC	4,46	GWO	4,43	GWO	4,42
GWO	4,74	ABC	4,92	ABC	4,85	ABC	4,62	SSA	4,46	SSA	4,55	SSA	4,62
WOA	5,53	WOA	5,67	WOA	5,72	WOA	5,68	WOA	5,61	WOA	5,64	WOA	5,58
DE	7,14	CS	7,73	CS	7,37	CS	7,18	CS	7,07	HHO	6,95	HHO	6,78
HHO	7,37	HHO	7,74	HHO	7,61	HHO	7,41	HHO	7,18	CS	7,00	CS	6,90
SOS	7,50	DE	7,99	DE	7,81	DE	7,77	DE	7,77	DE	7,81	DE	7,87
CS	7,91	SOS	8,00	SOS	8,41	SOS	8,69	SOS	8,97	SOS	9,14	SOS	9,28
SCA	9,84	SCA	10,10	SCA	10,26	SCA	10,43	SCA	10,56	SCA	10,70	SCA	10,80

Tüm eşik seviyelerinde test edilen 11 algoritmanın ortalama Friedman puanları hesaplanmış ve bu ortalamalara dayalı performans hiyerarşisi Tablo 5'te özetlenmiştir. 100 görüntünün yedi farklı seviyede eşik değerlerini belirleme görevinde, MFO en iyi performans gösteren algoritma olarak öne çıkmaktadır. PSO, ikinci en etkili algoritma olarak MFO'yu takip ederken, SSA üçüncü sırada yer almaktadır. Bu öncü algoritmaların ardından GWO ve ABC gelmektedir. Değerlendirilen algoritmalar arasında en düşük sıralamaya sahip olanlar ise SOS ve SCA'dır.

Tablo 5. Tüm eşik seviyelerinde MSA'ların ortalama Friedman puanları ve sıralamaları

MFO	PSO	SSA	GWO	ABC	WOA	HHO	CS	DE	SOS	SCA
2,73	2,97	4,36	4,49	4,52	5,64	7,29	7,31	7,74	8,57	10,38

3.2.3. Önerilen Çok Aşamalı Hibrit Algoritmaların Performans Değerlendirmesi

Önceki bölümde sunulan istatistiksel analiz sonuçları, 100 görüntünün $m=2, 3, 4, 5, 6, 7$ ve 8 seviyelerinde segmentasyon için $maxFEs = 500 \times m$ durdurma koşulu altında yapılan deneylerden elde edilmiştir. Bu sonuçlar, MFO, PSO ve SSA'nın sırasıyla en iyi üç performans gösteren algoritma olduğunu ortaya koymaktadır. Bu bulgular doğrultusunda, bu çalışma üç farklı çok aşamalı hibrit optimizasyon algoritması tanıtmıştır. Bu algoritmalar, aynı $maxFEs = 500 \times m$ sonlandırma kriterine uygun olarak $m=2, 4, 6$ ve 8 seviyelerinde 100 görüntüyü segmentasyon için uygulanmıştır. Bu aşamada hem Kapur entropisi hem de Otsu yöntemi amaç fonksiyonu olarak kullanılmış olup elde edilen veriler Tablo 6'da özetlenmiştir. Tablo 6'dan görüleceği üzere, Kapur entropisi kullanıldığında MFO-PSO-SSA algoritması, $m=2, 4$ ve 6 seviyelerinde görüntü segmentasyonunda başarılı performans göstermektedir. Özellikle, $m=2$ gibi düşük segmentasyon seviyelerinde önerilen üç algoritmanın Friedman puanları neredeyse özdeşdir. Ancak eşik seviyeleri yükseldikçe puanlar arasındaki farklılıklar daha belirgin hale gelmektedir. Bu durumlarda, MFO-SSA ve MFO-PSO hibrit algoritmaları sırasıyla ikinci ve üçüncü sırada yer almaktadır. $m=8$ seviyesindeki segmentasyon için performans sıralaması MFO-PSO, MFO-SSA ve MFO-PSO-SSA şeklinde değişmekte olup, MFO-PSO ile MFO-SSA'nın sonuçları birbirine oldukça yakın çıkmaktadır. Tabloda gösterildiği gibi, Kapur entropisi için bu üç çok aşamalı hibrit algoritma, değerlendirilen 11 MSA'nın arasında en iyi performans gösteren MFO'yu, 100 görüntünün $2, 4, 6$ ve 8 seviyelerinde segmentasyonunda aşmaktadır. Otsu yöntemi amaç fonksiyonu olarak kullanıldığında ise, MFO-SSA hibrit algoritması tüm eşik seviyelerinde üstün segmentasyon performansı sağlamıştır. Genellikle MFO-PSO, MFO-SSA'nın hemen ardından ikinci sırada yer almaktadır. Buna karşılık, MFO-PSO-SSA algoritması, Otsu yöntemi için diğer iki önerilen yöntemden daha az etkili kalmıştır. Yine de tablodaki Friedman puanlarına yakından bakıldığında, $m=2, 4$ ve 6 için ikinci ve üçüncü sırada yer alan algoritmaların puanlarının oldukça benzer olduğu görülmektedir.

Tablo 6. Önerilen algoritmaların Friedman sıralamaları ve puanları

Kapur entropisi							
m=2		m=4		m=6		m=8	
MFO_PSO_SSA	2,485	MFO_PSO_SSA	2,379	MFO_PSO_SSA	2,299	MFO_PSO	2,259
MFO_SSA	2,486	MFO_SSA	2,398	MFO_SSA	2,315	MFO_SSA	2,260
MFO_PSO	2,489	MFO_PSO	2,433	MFO_PSO	2,343	MFO_PSO_SSA	2,304
MFO	2,539	MFO	2,788	MFO	3,041	MFO	3,176
Otsu yöntemi							
m=2		m=4		m=6		m=8	
MFO_SSA	2,495	MFO_SSA	2,367	MFO_SSA	2,106	MFO_SSA	2,002
MFO_PSO	2,495	MFO_PSO_SSA	2,371	MFO_PSO	2,201	MFO_PSO	2,155
MFO_PSO_SSA	2,495	MFO_PSO	2,377	MFO_PSO_SSA	2,225	MFO_PSO_SSA	2,298
MFO	2,512	MFO	2,883	MFO	3,467	MFO	3,544

3.2.4. Görüntü Segmentasyonu Performans Metrikleri

Bu görüntü segmentasyonu çalışmasında, değerlendirme metrikleri uygunluk fonksiyonu, PSNR (Tepe Sinyal-Gürültü Oranı), SSIM (Yapısal Benzerlik İndeks Ölçüsü) ve FSIM (Özellik Benzerlik İndeksi) olarak belirlenmiştir. Otsu yöntemi ve Kapur entropi fonksiyonları uygunluk fonksiyonu olarak kullanılmış olup algoritmalar bu değerleri maksimize etmeye çalışmıştır. Dolayısıyla, daha yüksek bir uygunluk değeri algoritmanın etkinliğini göstermektedir.

PSNR, SSIM ve FSIM, segmente edilmiş görüntülerin kalitesini değerlendirmek için kullanılmıştır. PSNR (Tepe Sinyal-Gürültü Oranı), (Avcibas, Sankur, & Sayood, 2002) işlenen görüntüdeki maksimum sinyal gücünün gürültüye oranını ölçer ve bu da görüntü yeniden oluşturma kalitesinin bir ölçüsüdür. Ortalama Kare Hata (MSE), piksel bazında hataları hesaplar ve ortalama bir değer üretir; bu değer daha sonra PSNR hesaplamasında kullanılır. MSE, orijinal ve segmente edilmiş görüntüler arasındaki yoğunluk farkını temsil eder. Daha yüksek bir PSNR değeri, daha iyi segmentasyon kalitesini işaret eder. PSNR değeri Denklem 62 kullanılarak hesaplanmaktadır.

$$PSNR = 10 \log_{10} \frac{255^2}{\frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|x(i, j) - y(i, j)\|^2} \quad (62)$$

Denklemde; x , orijinal görüntüyü, y , segmente edilmiş görüntüyü ve (m, n) görüntülerdeki satır ve sütun sayısını göstermektedir.

SSIM(Yapısal Benzerlik İndeksi), (Wang, vd., 2004) yapısal değişikliklere dayalı olarak görüntü bozulmasını değerlendiren algı tabanlı bir metriktir. Genellikle orijinal ve segmente edilmiş görüntüler arasındaki bağımlılığı değerlendirmek için kullanılır. Daha yüksek bir SSIM değeri, daha iyi eşikleme kalitesini gösterir. SSIM, aşağıdaki formül kullanılarak hesaplanır:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (36)$$

Burada μ_x , μ_y ortalama değerleri, σ_x , σ_y standart sapmaları, σ_{xy} orijinal ve segmente edilmiş görüntüler arasındaki korelasyonu gösterir ve C_1 , C_2 sıfıra bölme işlemi önlemek için kullanılan sabitlerdir. FSIM (Özellik Benzerlik İndeksi), (Zhang L. , vd., 2011) orijinal ve segmente edilmiş görüntüler arasındaki yapısal benzerliği tahmin etmek için kullanılır. Tanımı şu şekildedir:

$$FSIM = \frac{\sum_{x \in \Omega} S_L(x) \cdot PC_m(x)}{\sum_{x \in \Omega} PC_m(x)} \quad (37)$$

Burada Ω , tüm görüntüyü temsil eder ve $S_L(x)$, çok seviyeli eşikleme ile elde edilen segmente görüntünün giriş görüntüsüne olan benzerliğini ölçer.

Bu tezde, Kapur entropisi amaç fonksiyonu olarak kullanılarak 100 görüntüden oluşan bir veri seti için, geliştirilen üç çok aşamalı hibrit optimizasyon algoritmasının yanı sıra, 11 algoritma arasından en iyi performans gösteren MFO algoritmasının elde ettiği amaç fonksiyonu, PSNR, SSIM ve FSIM ortalama değerleri Tablo 7'de verilmiştir. Veri setinin büyük boyutu nedeniyle, algoritmaların performansı sonuçların ortalaması alınarak değerlendirilmiştir. Tablo 7'deki bulgular, MFO-PSO-SSA yaklaşımının görüntü segmentasyonu görevlerinde diğer yöntemlere göre daha başarılı olduğunu göstermektedir. Görüntü segmentasyonunda eşik seviyesi sayısı arttıkça problemin karmaşıklığı da

artmaktadır. Çalışmanın en zorlu senaryosu olan $m=8$ seviye segmentasyonda önerilen MFO-PSO-SSA yöntemi, amaç fonksiyonu, PSNR ve FSIM için en yüksek değerleri üretmiştir. Ancak $m=8$ seviyesindeki SSIM ölçütü için MFO-SSA yöntemi diğerlerini geçmiştir. Tablo 7'de her bir eşik seviyesi (m) için dört algoritma ve dört değerlendirme metriği bazında en iyi sonuçlar karşılaştırılmış ve en iyi değerler vurgulanmıştır. Bu analize göre, toplam 16 durumdan ($4 \text{ algoritma} \times 4 \text{ metrik}$) 13 durumda önerilen hibrit algoritmalar en yüksek sonuçları elde etmiştir. Bu 13 üstün sonuçtan 9'u MFO-PSO-SSA yöntemine ait olup, bu durum karmaşık segmentasyon problemlerinin çözümündeki başarısını ortaya koymaktadır.

Tablo 7. Önerilen çok aşamalı hibrit algoritmaların kapur entropisi için ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri

Algoritma	m	Uygunluk Değeri	PSNR	SSIM	FSIM
MFO	2	17,84419	13,82603	0,383404	0,651433
MFO_PSO		17,84444	13,83012	0,383847	0,651288
MFO_SSA		17,84437	13,82929	0,383774	0,651385
MFO_PSO_SSA		17,84445	13,83042	0,384004	0,651455
MFO	4	26,76949	18,2205	0,593201	0,771525
MFO_PSO		26,77226	18,20227	0,592666	0,771018
MFO_SSA		26,77038	18,21327	0,59298	0,771311
MFO_PSO_SSA		26,77161	18,2222	0,592999	0,771381
MFO	6	34,5974	21,24321	0,704456	0,839871
MFO_PSO		34,60706	21,24411	0,705355	0,839852
MFO_SSA		34,60465	21,23289	0,704765	0,839788
MFO_PSO_SSA		34,61113	21,2318	0,70476	0,839633
MFO	8	41,59999	23,57691	0,776035	0,883075
MFO_PSO		41,6238	23,59599	0,777449	0,883705
MFO_SSA		41,62297	23,61054	0,778122	0,883812
MFO_PSO_SSA		41,63235	23,61355	0,777789	0,884151

Otsu yöntemi amaç fonksiyonu olarak kullanıldığında elde edilen ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri Tablo 8'de özetlenmiştir. Veriler, önerilen MFO_SSA algoritmasının diğerlerine kıyasla üstün segmentasyonu sonuçları sunduğunu göstermektedir. Otsu yöntemi kullanıldığında, MFO-SSA algoritması tüm eşik seviyelerinde en iyi performans gösteren algoritmadır. Tablo 8'de her bir eşik seviyesi (m) için dört algoritma ve dört değerlendirme metriği bazında en iyi sonuçlar karşılaştırılmış ve en iyi değerler vurgulanmıştır. Bu değerlendirmeye göre, toplam 16 senaryoda ($4 \text{ algoritma} \times 4$

metrik), önerilen hibrit algoritmalar en iyi sonuçları elde etmiştir. Bu başarılarından 15'i MFO-SSA yöntemine, 1'i ise MFO-PSO-SSA yöntemine aittir. $m=2$ seviyesinde, önerilen algoritmaların performansları birbirine oldukça yakın olsa da, yine de temel algorithmadan daha üstün sonuçlar vermektedir.

Bu çalışmada, önerilen algoritmaların segmentasyonu performansı, Berkeley veri setinin test klasöründen alınan 100 görüntü kullanılarak değerlendirilmiştir. Buradaki amaç, sadece birkaç görüntüde iyi performans göstermek için özel olarak tasarlanmış bir algoritma oluşturmak değil, segmentasyonu zorluğuna geniş çapta uygulanabilir bir çözüm geliştirmektir. Katılım sağlayan çok sayıda görüntü nedeniyle, Şekil 4'te yer alan örnek görüntülerin algoritmalar tarafından işlenen amaç fonksiyonu, PSNR, SSIM ve FSIM sonuçları, Kapur entropisi için Tablo 9'da ve Otsu yöntemi için Tablo 10'da ayrıntılı olarak sunulmuştur. Bu tablolardaki en iyi sonuçlar açıklık kazandırmak adına vurgulanmıştır. Örnek görüntüler alfabetik olarak şu şekilde etiketlenmiştir: I1: '102061.jpg', I2: '126007.jpg', I3: '208001.jpg', I4: '299086.jpg', I5: '55073.jpg', I6: '86068.jpg'.

Tablo 8. Önerilen çok aşamalı hibrit algoritmaların otsu yöntemi için ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri)

Algoritma	m	Uygunluk Değeri	PSNR	SSIM	FSIM
MFO	2	2633,995	15,29056	0,462937	0,698109
MFO_PSO		2633,996	15,29064	0,46294	0,698111
MFO_SSA		2633,996	15,29064	0,46294	0,698111
MFO_PSO_SSA		2633,996	15,29064	0,46294	0,698111
MFO	4	2836,16	19,55555	0,654512	0,811199
MFO_PSO		2836,188	19,55849	0,654752	0,811184
MFO_SSA		2836,194	19,5621	0,654932	0,811217
MFO_PSO_SSA		2836,191	19,55942	0,654876	0,81121
MFO	6	2892,525	22,41613	0,750567	0,867664
MFO_PSO		2892,715	22,44533	0,752123	0,867986
MFO_SSA		2892,717	22,44792	0,752319	0,868083
MFO_PSO_SSA		2892,716	22,44924	0,752197	0,868013
MFO	8	2915,606	24,48735	0,805748	0,899569
MFO_PSO		2915,83	24,52562	0,807568	0,89998
MFO_SSA		2916,068	24,55537	0,808591	0,900425
MFO_PSO_SSA		2915,851	24,53289	0,808064	0,900002

Her iki tablodaki verilerden de açıkça görülmektedir ki, önerilen çok aşamalı hibrit optimizasyonu algoritmaları, çok seviyeli eşikleme görüntüsü segmentasyonunda tüm

değerlendirilen metriklerde MFO algoritmasından daha üstün performans sergilemektedir. Ayrıca, tablolar, Kapur entropisi ile MFO_PSO_SSA algoritmasının diğer önerilen yöntemleri biraz olsa da geride bıraktığını, Otsu yöntemiyle ise MFO_SSA algoritmasının diğerlerine kıyasla daha üstün performans gösterdiğini ortaya koymaktadır.

Tablo 9. Veri setindeki örnek görüntüler için kapur entropisi amaç fonksiyonu kullanılarak elde edilen amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri

		Uygunluk Değeri				PSNR			
Algoritma	m								
		2	4	6	8	2	4	6	8
MFO	I1	17,69003	26,47625	34,25803	41,39269	12,63063	17,23177	20,5698	23,31585
	I2	17,34999	25,66175	33,58903	40,65254	13,36386	15,86606	20,23743	22,29714
	I3	18,10177	26,68362	34,40136	41,30258	13,21988	17,07483	19,7074	22,41689
	I4	16,7066	25,76408	33,66292	40,42434	14,95835	18,00511	21,57375	24,3063
	I5	18,26659	27,26019	35,09989	42,0557	15,57046	18,98983	22,09654	24,16264
	I6	17,57639	26,99838	34,95202	41,78708	11,12242	17,93054	21,24616	23,63645
MFO_PSO	I1	17,69003	26,48014	34,27976	41,38381	12,63096	17,22865	20,48407	23,5696
	I2	17,34999	25,68124	33,57614	40,65917	13,36386	15,89284	20,09231	22,61923
	I3	18,10177	26,68168	34,38666	41,38351	13,21988	17,13951	19,73422	22,78403
	I4	16,7074	25,7738	33,67028	40,46196	15,186	18,18321	21,42911	24,40765
	I5	18,26662	27,26074	35,10606	42,07123	15,56563	18,96633	22,12662	24,10369
	I6	17,5781	26,9995	34,98662	41,79322	11,19321	17,91729	21,34872	23,64321
MFO_SSA	I1	17,69003	26,47591	34,28174	41,42228	12,63096	17,17836	20,34148	23,59427
	I2	17,34999	25,65677	33,59591	40,64017	13,36386	16,12417	20,27905	22,35169
	I3	18,10177	26,69151	34,3786	41,38838	13,21988	17,04033	19,95303	22,52912
	I4	16,71235	25,77911	33,67085	40,46062	15,11713	18,13565	21,29514	24,34586
	I5	18,26662	27,26075	35,10613	42,06479	15,56455	18,96307	22,12342	24,18908
	I6	17,5781	26,99594	34,94733	41,8133	11,19321	17,93358	21,2659	23,72285
MFO_PSO_SSA	I1	17,69003	26,48132	34,27295	41,39244	12,63096	17,19021	20,46585	23,67243
	I2	17,34999	25,65632	33,59861	40,67043	13,36386	15,63755	20,37275	22,22613
	I3	18,10177	26,68784	34,39289	41,4034	13,21988	17,09338	19,52461	22,47561
	I4	16,71095	25,7503	33,70736	40,46422	15,22286	18,2429	21,23105	24,42757
	I5	18,26662	27,26079	35,08852	42,09163	15,56455	18,95124	22,13302	24,23761
	I6	17,57668	26,99597	34,97093	41,83164	11,12515	17,93333	21,3292	23,63156
		SSIM				FSIM			
Algoritma	m								
		2	4	6	8	2	4	6	8
MFO	I1	0,354237	0,58557	0,723453	0,807998	0,701161	0,771591	0,822443	0,865235
	I2	0,362315	0,488616	0,711465	0,770569	0,71043	0,751847	0,818817	0,853899
	I3	0,171466	0,412828	0,571354	0,714311	0,581245	0,724572	0,805235	0,864582
	I4	0,490799	0,680998	0,759456	0,813534	0,68986	0,732536	0,793298	0,8448
	I5	0,32712	0,534732	0,694183	0,772297	0,677738	0,81167	0,892362	0,92783
	I6	0,2916	0,613455	0,756667	0,832912	0,487121	0,724989	0,842439	0,895477

Tablo 9'un devamı

MFO_PSO	I1	0,354236	0,584701	0,717426	0,820381	0,701162	0,772142	0,821404	0,867165
	I2	0,362315	0,49834	0,706946	0,782188	0,71043	0,750649	0,818114	0,859052
	I3	0,171466	0,414785	0,573191	0,73243	0,581245	0,728442	0,806148	0,868033
	I4	0,508166	0,685739	0,762191	0,815878	0,693626	0,735398	0,792051	0,846564
	I5	0,32664	0,532624	0,69557	0,769191	0,677222	0,811376	0,892789	0,926906
	I6	0,293783	0,612018	0,759822	0,833664	0,487581	0,723949	0,84503	0,895714
MFO_SSA	I1	0,354236	0,581786	0,710473	0,822343	0,701162	0,771578	0,82031	0,867954
	I2	0,362315	0,503149	0,714196	0,776248	0,71043	0,753826	0,818201	0,855222
	I3	0,171466	0,411363	0,588206	0,714557	0,581245	0,721487	0,80906	0,866571
	I4	0,502391	0,683506	0,757549	0,816198	0,690501	0,734541	0,788927	0,845917
	I5	0,326528	0,531808	0,695395	0,773207	0,677069	0,811391	0,892733	0,928164
	I6	0,293783	0,611649	0,755902	0,836151	0,487581	0,723728	0,841909	0,897359
MFO_PSO_SSA	I1	0,354236	0,582626	0,71506	0,825256	0,701162	0,771827	0,822171	0,867889
	I2	0,362315	0,474897	0,718537	0,769775	0,71043	0,749888	0,819413	0,855013
	I3	0,171466	0,411192	0,558882	0,712295	0,581245	0,726207	0,803949	0,8665
	I4	0,511636	0,685516	0,756887	0,816771	0,691514	0,736381	0,787839	0,847431
	I5	0,326528	0,531103	0,695953	0,775682	0,677069	0,811059	0,892968	0,929094
	I6	0,292086	0,611576	0,758853	0,832392	0,487715	0,723694	0,844243	0,895604

Tablo 10. Veri集中的 örnek görüntüler için otsu yöntemi amaç fonksiyonu kullanılarak elde edilen amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri


Algoritma		Uygunluk Değeri				PSNR			
		m				m			
		2	4	6	8	2	4	6	8
MFO	I1	3820,206	4062,809	4128,671	0,828656	13,05157	16,99337	20,62402	23,00984
	I2	1734,608	1922,618	1968,655	0,852403	14,975	19,73265	22,2206	24,61003
	I3	1920,698	2142,992	2199,644	0,85019	15,28047	19,13782	21,59822	23,49977
	I4	594,1611	662,2158	683,5494	0,869386	17,74186	21,9388	24,69717	26,31627
	I5	2136,841	2377,301	2444,668	0,927074	16,60521	20,76896	23,87038	26,05034
	I6	909,0758	1019,335	1056,237	0,861409	15,35904	19,18079	20,9264	21,9811
MFO_PSO	I1	3820,207	4062,897	4128,7	0,827595	13,05163	16,99718	20,42608	23,24842
	I2	1734,609	1922,63	1969,455	0,855697	14,97601	19,73075	22,48453	24,67378
	I3	1920,699	2143,003	2200,03	0,851369	15,27974	19,13913	21,64275	23,66733
	I4	594,1611	662,2798	683,5607	0,869411	17,74186	21,88146	24,69047	26,24306
	I5	2136,841	2377,34	2444,71	0,926926	16,60521	20,78169	23,86132	25,9763
	I6	909,0758	1019,366	1056,719	0,861581	15,35904	19,19075	20,92868	22,07112
MFO_SSA	I1	3820,207	4062,897	4128,923	0,828941	13,05163	16,99718	20,59253	23,31018
	I2	1734,609	1922,63	1969,228	0,855038	14,97601	19,73075	22,44768	24,52694
	I3	1920,699	2143,003	2200,033	0,851479	15,27974	19,138	21,65283	23,66522
	I4	594,1611	662,2798	683,2745	0,868634	17,74186	21,88146	24,66759	26,337
	I5	2136,841	2377,34	2444,83	0,927213	16,60521	20,78162	23,87543	26,06365
	I6	909,0758	1019,366	1056,918	0,861862	15,35904	19,19155	20,93244	22,07909
MFO_PSO_SSA	I1	3820,207	4062,897	4128,829	0,826739	13,05163	16,99718	20,382	23,26725

Tablo 10'un devamı


	I2	1734,609	1922,63	1969,613	0,856452	14,97601	19,73075	22,51818	24,74961
	I3	1920,699	2143,003	2199,727	0,850902	15,27974	19,138	21,62017	23,67756
	I4	594,1611	662,2798	683,8634	0,870188	17,74186	21,88146	24,72449	26,23669
	I5	2136,841	2377,339	2444,588	0,926727	16,60521	20,78203	23,84659	26,02878
	I6	909,0758	1019,366	1056,687	0,861637	15,35904	19,1911	20,92759	22,03923
SSIM					FSIM				
Algoritma	m				m				
		2	4	6	8	2	4	6	8
MFO	I1	0,38558	0,567799	0,711703	0,782967	0,711397	0,770242	0,828656	0,871762
	I2	0,430921	0,688279	0,753955	0,815024	0,71417	0,80045	0,852403	0,888185
	I3	0,327232	0,55659	0,671787	0,747211	0,649913	0,784506	0,85019	0,885899
	I4	0,568087	0,741008	0,834504	0,870264	0,715357	0,81818	0,869386	0,896064
	I5	0,428445	0,691616	0,821893	0,884388	0,732089	0,870099	0,927074	0,952296
	I6	0,495107	0,708202	0,790448	0,831788	0,664433	0,807444	0,861409	0,885796
MFO_PSO	I1	0,385575	0,567576	0,705077	0,795389	0,711377	0,770265	0,827595	0,875211
	I2	0,43092	0,688545	0,76609	0,816736	0,714168	0,800618	0,855697	0,888418
	I3	0,327137	0,556712	0,67438	0,754165	0,649867	0,784518	0,851369	0,887087
	I4	0,568087	0,739501	0,834696	0,868528	0,715357	0,817921	0,869411	0,894832
	I5	0,428445	0,691068	0,82227	0,881052	0,732089	0,87037	0,926926	0,951536
	I6	0,495107	0,708601	0,791165	0,834334	0,664433	0,807315	0,861581	0,887085
MFO_SSA	I1	0,385575	0,567576	0,712235	0,797758	0,711377	0,770265	0,828941	0,87591
	I2	0,43092	0,688545	0,765027	0,812703	0,714168	0,800618	0,855038	0,888584
	I3	0,327137	0,556642	0,674898	0,75427	0,649867	0,784503	0,851479	0,887089
	I4	0,568087	0,739501	0,833692	0,870642	0,715357	0,817921	0,868634	0,896557
	I5	0,428445	0,691064	0,824137	0,884992	0,732089	0,870373	0,927213	0,952292
	I6	0,495107	0,708646	0,791527	0,834702	0,664433	0,807297	0,861862	0,887316
MFO_PSO_SSA	I1	0,385575	0,567576	0,704267	0,796235	0,711377	0,770265	0,826739	0,875422
	I2	0,43092	0,688545	0,767285	0,818665	0,714168	0,800618	0,856452	0,887823
	I3	0,327137	0,556642	0,673589	0,754604	0,649867	0,784503	0,850902	0,887465
	I4	0,568087	0,739501	0,835724	0,868987	0,715357	0,817921	0,870188	0,895196
	I5	0,428445	0,691069	0,821607	0,884065	0,732089	0,870375	0,926727	0,951982
	I6	0,495107	0,708624	0,791217	0,833473	0,664433	0,807317	0,861637	0,886589

Bu çalışmada segmentasyonu algoritmasının geliştirilmesinde kullanılan çok sayıda görüntü nedeniyle, Şekil 4'te sunulan örnek görüntüler için kutu grafikleri verilmiştir. Altı örnek görüntünün m=8 seviye eşikleme problemi için Kapur entropisi ve Otsu yöntemi amaç fonksiyonları kullanılarak elde edilen kutu grafikleri sırasıyla Şekil 5 ve Şekil 6'da gösterilmiştir. Y ekseninde, ilgili eşik seviyesinde görüntünün RGB kanalları için ayrı ayrı hesaplanan amaç fonksiyonu değerlerinin ortalaması yer almaktadır. Grafikler, her bir problemin 25 kez tekrarlanması sonucunda toplam 25 noktadan oluşmaktadır. Şekillerdeki kutu grafikleri, temel algoritma (MFO) ve önerilen çok aşamalı hibrit MSA algoritmaları

kullanılarak oluşturulmuştur. Elde edilen sonuçlardan, önerilen çok aşamalı hibrit MSA algoritmalarının sağladığı çözümlerin kalitesinin MFO algoritmasından daha yüksek olduğu görülmektedir.




Şekil 5. Örnek görüntüler için kutu grafikleri (Kapur entropisi, m=8)



Şekil 6. Örnek görüntüler için kutu grafikleri (Otsu yöntemi, m=8)

Bu çalışmadaki test görüntülerinin sayısı, literatürdeki çoğu çalışmaya kıyasla önemli ölçüde fazladır. Bu nedenle, tüm görüntüler ve algoritmalar için segmente edilmiş

görüntüleri sunmak mümkün olmamıştır. Bu nedenle, Tablo 6'deki Friedman puanları ve Tablo 7 ve Tablo 8'deki ortalama amaç fonksiyonu, PSNR, SSIM ve FSIM değerleri dikkate alındığında, önerilen MFO-PSO-SSA algoritmasının Kapur entropisi için daha iyi performans gösterdiği, önerilen MFO-SSA algoritmasının ise Otsu yöntemi için daha başarılı olduğu açıkça görülmektedir. Bu nedenlerden dolayı, Kapur entropisi için MFO-PSO-SSA kullanılarak elde edilen segmente edilmiş görüntüler Şekil 7'de, Otsu yöntemi için MFO-SSA kullanılarak elde edilen segmente edilmiş görüntüler ise Şekil 8'de sunulmuştur.



Şekil 7. MFO-PSO-SSA ile segmente edilmiş görüntüler (Kapur entropisi)



Şekil 8. MFO-SSA ile segmente edilmiş görüntüler (Otsu yöntemi)

3.3. Önerilen WChOA-UMD Algoritmasının Deneysel Bulguları

3.3.1. Önerilen WChOA-UMD Algoritmasının Performansını Test Etme ve Analiz Etme

Bu bölümde, önerilen WChOA-UMD algoritmasının deneysel sonuçları sunulmaktadır; burada önerilen algoritmanın birden fazla durumu temel algoritma ile karşılaştırılmaktadır. Geliştirilen WChOA-UMD'nin performansı, IEEE CEC 2020 problemleri (Yue, vd., 2020) kullanılarak değerlendirilmiştir. Özellikle, Tablo 11'de özetlenen on farklı problem, 10, 30, 50 ve 100 boyutlarında analiz edilmiştir. Analiz, güçlü

bir değerlendirme sağlamak amacıyla Friedman testi ve Wilcoxon ikili karşılaştırma testi gibi istatistiksel testler kullanılarak gerçekleştirilmiştir.

Tablo 11, çalışmada kullanılan fonksiyon türleri, arama aralıkları ve problem boyutları hakkında ayrıntılı bilgiler içermektedir. Bu fonksiyonları, meta sezgisel algoritmaların keşif, sömürü ve dengeli arama yeteneklerini değerlendirmek için özel olarak tasarlanmıştır. Tek modlu (unimodal) ve çok modlu (multimodal) fonksiyonlar sırasıyla algoritmanın sömürü ve keşif yeteneklerini değerlendirmek için kullanılmıştır. Birden fazla alt fonksiyonun birleştirildiği hibrit fonksiyonlar, algoritmanın keşif ve sömürü arasında denge kurma kapasitesini incelemek amacıyla kullanılmıştır. Bileşik fonksiyonlar ise, karmaşıklıkları nedeniyle gerçek dünya optimizasyonu zorluklarını simüle etmektedir; bu fonksiyonlar, birçok yerel minimuma sahip olup daha iyi bir arama stratejisi gerektirmektedir.

Bu çeşitli test fonksiyonlarının analizi yoluyla, çalışma, WChOA-UMD algoritmasının performansını farklı koşullar altında ve problem karmaşıklıklarında kapsamlı bir şekilde değerlendirmeyi amaçlamaktadır.

Tablo 11. CEC'2020 test paketi özeti

No.	Fonksiyon Türü	Fonksiyon Açıklaması	$F_i^* = F_i(x^*)$
F1	Tek modlu	Kaydırılmış ve Döndürülmüş Bent Cigar	100
F2	Çok modlu	Kaydırılmış ve Döndürülmüş Schwefel	1100
F3	Çok modlu	Kaydırılmış ve Döndürülmüş Lunacek bi-Rastrigin Fonksiyonu	700
F4	Çok modlu	Genişletilmiş Rosenbrock artı Griewangk	1900
F5	Hibrit	Hibrit Fonksiyon 1 (N = 3)	1700
F6	Hibrit	Hibrit Fonksiyon 2 (N = 4)	1600
F7	Hibrit	Hibrit Fonksiyon 3 (N = 5)	2100
F8	Bileşik	Bileşik Fonksiyon 1 (N = 3)	2200
F9	Bileşik	Bileşik Fonksiyon 2 (N = 4)	2400
F10	Bileşik	Bileşik Fonksiyon 3 (N = 5)	2500
Arama aralığı: $[-100,100]^D$, D: boyut sayısı (10, 30, 50, 100)			

3.3.2. Friedman ve Wilcoxon Testleri ile Algoritmaların Performanslarının İstatistiksel Analizi

Birden fazla algoritma veya koşul arasında performans farklılıklarını tespit etmek için Friedman testi olarak bilinen parametrik olmayan bir istatistiksel yöntem kullanılmıştır. Bu test, aynı deneysel kurulum altında çeşitli yöntemlerden veya algoritmalarından elde edilen tekrarlı ölçümleri analiz ederken özellikle etkilidir. Çalışmamızda, istatistiksel analiz 10 test

fonksiyonu, 25 bağımsız çalışma ve 9 algoritmayı kapsamaktadır. Tablo 12'de sunulan Friedman testi sonuçları, WChOA-UMD varyantlarının tüm deneylerde temel WChOA algoritmasından daha üstün performans sergilediğini ortaya koymuştur. Ortalama sıralama indeksi dikkate alındığında, Durum-4 varyantı WChOA-UMD varyantları arasında en başarılı olanı olarak belirlenmiştir. Ayrıca, boyutun artmasıyla algoritmaların performansı da değişime uğramıştır. Boyutun 10'dan 30'a, 50'e ve sonunda 100'e çıkarken, Durum-4 varyantının ortalamaya yakın sıralamalarını koruyabilmesi, bu algoritmanın daha büyük veri boyutlarında da tutarlı bir şekilde çalıştığını göstermektedir. Özellikle, boyutun artması durumunda WChOA algoritmasının sıralamasındaki düşüş (örneğin, boyut 10 için 5,897, boyut 100 için 6,709) karşısında, Durum-4'nin daha az etkilendiği gözlenmiştir. Bu, Durum-4'in daha yüksek boyutlarda da performans kaybını minimuma indirmesi ve genelleştirilmiş bir çözüm sunması yönündeki potansiyelini vurgulamaktadır. Bu sonuçlar, boyutun artmasıyla birlikte algoritmaların performansı üzerindeki etkileri incelemek için önemli bir referans sağlamaktadır.

Tablo 12. WChOA ve WChOA-UMD varyantları için friedman testi sıralamaları

Algoritma	Boyut = 10	Boyut = 30	Boyut = 50	Boyut = 100	Ortalama Sıralama
Durum-1	4.681	4.938	4.785	4.802	4,801 5 th
Durum-2	4.678	4.683	4.804	4.723	4,722 3 rd
Durum-3	4.826	4.795	4.623	4.590	4,708 2 nd
Durum-4	4.864	4.709	4.697	4.492	4,690 1 st
Durum-5	4.921	5.190	5.119	4.933	5,040 7 th
Durum-6	5.316	5.183	5.185	5.057	5,185 8 th
Durum-7	4.897	4.842	4.697	4.852	4,822 6 th
Durum-8	4.916	4.478	4.778	4.838	4,752 4 th
WChOA	5.897	6.178	6.307	6.709	6,272 9 th

Wilcoxon işaretli sıralar testi, başka bir parametrik olmayan istatistiksel yöntem olarak, iki ilişkili örneği karşılaştırmak ve popülasyonların ortalama sıralamalarının farklı olup olmadığını değerlendirmek için kullanılmıştır. Bu test, özellikle veriler normal dağılım varsayımlarını sağlamadığında, eşleştirilmiş t-testinin güçlü bir alternatifi olarak kullanılmaktadır. Birden fazla veri seti üzerinde algoritmaların veya varyantlarının göreceli performansını değerlendirmede özellikle yararlıdır. Bu çalışmada, Wilcoxon testi, algoritmaların performans metriklerini ikili karşılaştırmalar yaparak en iyi performans gösteren algoritmayı belirlemek için uygulanmıştır.

Tablo 13, temel WChOA algoritması ile UMD varyantları arasındaki Wilcoxon ikili karşılaştırmalarının sonuçlarını sunmaktadır. Tablodaki her hücre, toplam test fonksiyonlarının sayısını (bu tezde 10) temsil etmekte olup, (+ / = / -) notasyonu, ilgili WChOA-UMD varyantının temel algoritmaya kıyasla daha iyi, benzer veya daha kötü performans gösterdiği problem sayılarını belirtmektedir. Örneğin, durum-4'ün son sütunundaki (D = 100) (7/3/0), bu varyantın 7 problemde temel algoritmadan daha iyi performans gösterdiğini, 3 problemde benzer performans sergilediğini ve hiçbir problemde daha kötü performans göstermediğini ifade etmektedir.

Tablo 13. WChOA ve WChOA-UMD varyantları için Wilcoxon ikili karşılaştırma sonuçları

vs. WChOA +/-/-	Boyut = 10	Boyut = 30	Boyut = 50	Boyut = 100
Durum-1	5_5_0	6_4_0	6_4_0	5_5_0
Durum-2	5_5_0	6_4_0	4_6_0	7_3_0
Durum-3	4_6_0	5_5_0	6_4_0	7_3_0
Durum-4	4_6_0	5_5_0	5_5_0	7_3_0
Durum-5	5_5_0	4_6_0	4_6_0	6_4_0
Durum-6	4_5_1	4_6_0	5_5_0	6_4_0
Durum-7	4_6_0	5_5_0	6_4_0	5_5_0
Durum-8	4_6_0	5_5_0	7_3_0	5_5_0

Tüm WChOA-UMD varyantlarının performansı, 10, 30, 50 ve 100 boyutlarda analiz edilmiştir. Ana bulgular şunlardır:

- D = 10 boyut için, Case-1, Case-2 ve Case-5, tüm ikili karşılaştırmalarda en iyi (5/5/0) skorunu elde etmiştir.
- D = 30 boyut için, Case-1 ve Case-2 en yüksek (6/4/0) skorunu almıştır; Case-3, Case-4, Case-7 ve Case-8 ise temel algoritmadan daha iyi performans göstererek (5/5/0) skoruna ulaşmıştır.
- D = 50 boyut için, Case-8 tüm durumlar arasında en iyi (7/3/0) skorunu elde etmiştir. Ayrıca, Case-4 ve Case-6, temel algoritmadan daha iyi performans göstererek (5/5/0) skoruna ulaşmış, Case-1, Case-3 ve Case-7 ise (6/4/0) skoruyla daha iyi performans sergilemiştir.
- Son olarak, D = 100 boyut için, tüm WChOA-UMD varyantları orijinal algoritmaya kıyasla üstün performans göstermiştir.


Bu sonuçlar, WChOA-UMD varyantlarının farklı problem boyutları ve karmaşıklıklarında arama performansını artırma konusundaki etkinliğini göstermektedir.

3.3.3. Önerilen WChOA-UMD Yönteminin Görüntü Segmentasyonu Performansı

Bu bölümde, önerilen WChOA-UMD algoritmasının çok seviyeli görüntü segmentasyonu performansı analiz edilmiştir. Deneysel çalışmalar, Berkeley görüntü segmentasyonu veri tabanından (BSD300, n.d.) seçilen 10 renkli görüntü üzerinde gerçekleştirilmiştir. Test görüntüleri ve bunlara karşılık gelen histogramlar Şekil 9'da sunulmuştur. Algoritmanın zorlu problemleri çözme yeteneğini değerlendirmek için özellikle karmaşık histogramlara sahip görüntüler seçilmiştir. Histogramlar incelendiğinde, test görüntülerinin çeşitli parlaklık ve renk dağılımlarına sahip olduğu açıkça görülmektedir. WChOA-UMD'nin çok seviyeli eşikleme görüntü segmentasyonu performansını değerlendirmek için yaygın olarak kullanılan amaç fonksiyonu olan Kapur entropisi ve Otsu yöntemi kullanılmıştır. WChOA-UMD'nin performansı, (ABC, CS, GWO, HHO, MFO, SCA, SSA) gibi birçok meta sezgisel algoritma ile karşılaştırılmıştır.


Deneysel çalışmalar, 10 renkli görüntü, 2 eşikleme fonksiyonu (Kapur entropisi ve Otsu yöntemi), 16 MSA (WChOA, 8 WChOA-UMD varyantı ve 7 rakip algoritma), 6 farklı eşik seviyesi ($m = 2, 4, 6, 8, 10, 12$) ve iki arama süreci sonlandırma kriteri ($maxFEs = 500 \times m$ ve $maxFEs = 1000 \times m$, burada m eşik seviyelerinin sayısı ve $maxFEs$ sonlandırma kriterini temsil etmektedir) kullanılarak yürütülmüştür.

Sonuç olarak, önerilen WChOA-UMD yönteminin çok seviyeli eşikleme görüntü segmentasyonu performansını değerlendirmek üzere toplamda $11520 = 10 \text{ görüntü} \times 3 \text{ kanal (RGB)} \times 2 \text{ eşikleme fonksiyonu} \times 16 \text{ MSA} \times 6 \text{ eşik seviyesi} \times 2 \text{ arama süreci sonlandırma kriteri}$ deneyi gerçekleştirilmiştir. Her bir algoritma, Tablo 14'te özetlenen algoritmaların orijinal parametre ayarları kullanılarak her bir segmentasyon görevi için 25 bağımsız çalıştırma ile yürütülmüştür. Bu kapsamlı deneysel tasarım, önerilen yöntemin farklı koşullar ve karmaşıklıklar altında kapsamlı bir şekilde değerlendirilmesini sağlamaktadır.



Şekil 9. Test görüntüleri ve histogramları (soldan sağa: 12003.jpg, 108073.jpg, 124084.jpg, 232038.jpg, 323016.jpg, 106024.jpg, 291000.jpg, 12084.jpg, 61060.jpg, 65010.jpg)

Şekil 9'un devamı



Tablo 14. Algoritma ayarları

Algoritma	Ayarlar
WChOA	arama ajanı sayısı = 30, ...
ABC	koloni boyutu = 50, SN = koloni boyutu / 2, limit = D *
CS	yuva sayısı = 25, olasılık = 0.25, beta = 1.5
GWO	arama ajanı sayısı = 30
HHO	N = 30, Bfid = 1, nD = 10, Jr = 0.25
MFO	moth sayısı = 30
SCA	arama ajanı sayısı = 30, a = 2
SSA	salp popülasyon boyutu = 30

3.3.4. İstatistiksel Analiz

Bu alt bölümde, segmentasyon sürecinin sonuçları, Kapur entropisi ve Otsu yöntemi amaç fonksiyonları kullanılarak sunulmaktadır. 16 metasezgisel arama (MSA) algoritmasının amaç fonksiyonu değerleri, 10 test görüntüsü, 6 farklı eşik seviyesi ve R-G-B kanalları için analiz edilmiştir. İstatistiksel karşılaştırmalar Friedman testi kullanılarak gerçekleştirilmiştir. Otsu yöntemi ve Kapur entropisi amaç fonksiyonları kullanılarak elde edilen analiz sonuçları, iki farklı *maxFEs* değeri için sırasıyla Tablo 15 ve Tablo 16'da verilmiştir.

Çok seviyeli görüntü segmentasyonunda, eşik seviyelerinin sayısındaki artış problem karmaşıklığını yükseltmektedir. Tablo 15 ve Tablo 16'da sunulan Friedman sıralamaları, arama uzayının karmaşıklığı arttıkça en üst sıralardaki algoritmalar ile rakipleri arasında önemli farklılıklar ortaya çıktığını göstermektedir. Eşik seviyesindeki değişiklikler, arama uzayının sınırlarını ve geometrik yapısını değiştirmekte ve bu da doğrudan algoritma performansını etkilemektedir.

Tablo 15. Algoritmaların farklı eşik seviyelerinde Friedman sıralamaları (Otsu yöntemi)

3*25run (RGB), $maxFEs=500*m$,					
m=2	m=4	m=6	m=8	m=10	m=12
Durum 2 (6,98)	Durum 2 (7,92)	Durum 7 (8,03)	Durum 8 (8,07)	Durum 7 (8,07)	Durum 8 (8,22)
WChOA (7,60)	WChOA (8,21)	WChOA (8,19)	WChOA (8,34)	WChOA (8,21)	WChOA (8,33)
HHO (9,50)	GWO (8,93)	GWO (8,89)	SCA (8,40)	MFO (8,68)	HHO (8,56)
SSA (9,63)	SSA (9,01)	MFO (8,98)	MFO (8,83)	SCA (8,98)	SCA (8,72)
SCA (9,73)	MFO (9,21)	SSA (9,37)	GWO (9,13)	SSA (8,99)	SSA (8,79)
MFO (9,84)	HHO (9,29)	HHO (9,41)	SSA (9,23)	HHO (9,13)	MFO (9,226)
GWO 9,85)	SCA (9,85)	SCA (9,42)	HHO (9,34)	GWO (9,44)	GWO (9,23)
ABC (10,33)	CS (9,98)	ABC (9,73)	CS (9,99)	ABC (9,78)	CS (9,53)
CS (10,79)	ABC (10,23)	CS (9,92)	ABC (10,26)	CS (10,05)	ABC (10,35)
3*25run (RGB), $maxFEs=1000*m$,					
m=2	m=4	m=6	m=8	m=10	m=12
WChOA (7,05)	Durum 1 (7,61)	Durum 2 (7,89)	Durum 8 (8,18)	Durum 1 (8,27)	Durum 8 (7,84)
Durum 1 (7,31)	WChOA (7,72)	WChOA (8,12)	WChOA (8,53)	WChOA (8,33)	WChOA (8,27)
SSA (9,61)	MFO (9,22)	GWO (9,03)	MFO (8,85)	SSA (8,91)	MFO (8,51)
SCA (9,89)	GWO (9,30)	MFO (9,11)	GWO (9,00)	HHO (9,069)	SSA (8,73)
MFO (10,00)	SCA 9,32)	HHO (9,12)	SCA (9,19)	GWO (9,074)	GWO (9,06)
HHO (10,09)	HHO (9,62)	SCA (9,38)	HHO (9,38)	SCA (9,13)	HHO (9,24)
GWO (10,14)	SSA (9,77)	SSA (9,79)	CS (9,54)	MFO (9,30)	SCA (9,35)
CS (10,67)	ABC (10,15)	CS (9,94)	SSA (9,58)	ABC (9,46)	CS (10,22)
ABC (10,80)	CS (10,36)	ABC (10,13)	ABC (10,10)	CS (9,89)	ABC (10,23)

Farklı algoritmaların farklı eşik seviyelerindeki değişken başarıları, sömürü ve keşif yeteneklerini dengeleme kapasiteleriyle ilişkilidir. Buna rağmen, sonuçlar önerilen WChOA-UMD yönteminin, tüm eşik seviyeleri ve $maxFEs$ değerleri için her iki eşikleme fonksiyonunda da temel algoritmadan ve diğer rakip algoritmalarından daha üstün performans sergilediğini göstermektedir (Otsu eşikleme fonksiyonu için $m=2$ ve $maxFEs = 1000 \times m$ durumu hariç).

Bu, önerilen yöntemin farklı karmaşıklık düzeylerindeki segmentasyon problemlerini ele alırken rakiplerine kıyasla daha dengeli bir arama yeteneğine sahip olduğunu göstermektedir. Ayrıca, çok seviyeli görüntü segmentasyonu alanında ilk kez uygulanan

WChOA algoritması, Friedman puanlarına göre her iki amaç fonksiyonu için ikinci en başarılı algoritma olarak yer almıştır.

Tablo 16. Algoritmaların farklı eşik seviyelerinde Friedman sıralamaları (Kapur entropisi)

3*25run (RGB), $maxFEs=500*m$,					
m=2	m=4	m=6	m=8	m=10	m=12
Durum 8 (7,80)	Durum 2 (8,44)	Durum 7 (8,33)	Durum 8 (7,98)	Durum 2 (8,47)	Durum 1 (8,59)
WCHOA (8,23)	WCHOA (8,77)	WCHOA (8,61)	SSA (8,28)	WCHOA (8,59)	GWO (8,62)
MFO (9,05)	GWO (8,80)	HHO (8,66)	MFO (8,67)	SSA (8,69)	HHO (8,82)
GWO (9,22)	MFO (8,83)	SSA (8,86)	GWO (8,73)	MFO (8,83)	WCHOA (8,826)
SSA (9,33)	SSA (9,07)	GWO (9,11)	HHO (8,79)	GWO (8,88)	SCA (8,83)
SCA (9,63)	HHO (9,15)	SCA (9,11)	WCHOA (8,95)	SCA (8,96)	SSA (9,07)
HHO (9,68)	SCA (9,22)	MFO (9,30)	SCA (9,00)	HHO (9,24)	MFO (9,09)
CS (10,23)	ABC (9,38)	ABC (9,38)	CS (9,65)	CS (9,57)	ABC (9,27)
ABC (10,34)	CS (9,66)	CS (9,68)	ABC (9,70)	ABC (9,59)	CS (9,72)
3*25run (RGB), $maxFEs=1000*m$,					
m=2	m=4	m=6	m=8	m=10	m=12
Durum 2 (7,65)	Durum 7 (8,16)	Durum 8 (8,48)	Durum 2 (8,38)	Durum 4 (8,44)	Durum 4 (8,18)
WCHOA (7,93)	WCHOA (8,22)	WCHOA (8,60)	GWO (8,67)	SCA (8,79)	HHO (8,53)
HHO (9,16)	GWO (8,82)	SCA (8,70)	MFO (8,72)	MFO (8,93)	MFO (8,61)
SSA (9,41)	MFO (8,91)	GWO (8,82)	SCA (8,73)	HHO (9,02)	GWO (8,71)
SCA (9,48)	HHO (8,99)	SSA (8,84)	WCHOA (8,74)	WCHOA (9,14)	WCHOA (8,86)
GWO (9,83)	SSA (9,07)	HHO (8,96)	HHO (8,78)	GWO (9,15)	SSA (8,98)
MFO (9,95)	ABC (9,41)	MFO (8,97)	SSA (9,17)	SSA (9,22)	SCA (9,33)
ABC (10,44)	CS (9,51)	ABC (9,38)	ABC (9,31)	ABC (9,28)	CS (9,49)
CS (10,48)	SCA (9,57)	CS (9,99)	CS (9,41)	CS (9,61)	ABC (9,59)

3.3.5. Amaç Fonksiyonu Değeri ile Performans Değerlendirme

Optimizasyon süreci boyunca, Otsu yöntemi ve Kapur entropisi amaç fonksiyonu olarak kullanılmıştır. Algoritmalar, bu amaç fonksiyonlarını maksimize etmeye çalışmıştır; yani daha yüksek bir amaç değeri, algoritmanın daha başarılı olduğunu göstermektedir. Her bir algoritma için Otsu yöntemi kullanılarak elde edilen ortalama amaç fonksiyonu değerleri, iki farklı sonlandırma kriteri ($maxFEs = 500 \times m$ ve $maxFEs = 1000 \times m$) için kaydedilmiş olup, sırasıyla Ek Tablo 1 ve Ek Tablo 2'de gösterilmiştir. Sonuçlar, WChOA ve önerilen WChOA-UMD varyantlarının neredeyse tüm deneylerde diğer algoritmalarından daha üstün performans sergilediğini ortaya koymaktadır.

Özellikle:

- $maxFEs = 500 \times m$ için yapılan 60 deneyin 53'ünde WChOA ve WChOA-UMD daha yüksek amaç fonksiyonu değerleri elde etmiştir.
- $maxFEs = 1000 \times m$ için yapılan 60 deneyin 49'unda bu üstünlüğü korumuştur.

- Bu deneyler arasında WChOA-UMD algoritması, $maxFEs = 500 \times m$ için 39 deneyde ve $maxFEs = 1000 \times m$ için 35 deneyde en iyi amaç fonksiyonu değerlerini sağlamıştır.

Bu bulgular, WChOA-UMD varyantının görüntü segmentasyonu performansını optimize etmedeki etkinliğini vurgulamaktadır.

Kapur entropisi kullanılarak her bir algoritma için elde edilen ortalama amaç fonksiyonu değerleri, $maxFEs = 500 \times m$ ve $maxFEs = 1000 \times m$ için analiz edilmiş olup, sonuçlar sırasıyla Ek Tablo 3 ve Ek Tablo 4'te sunulmuştur. Sonuçlar, WChOA ve önerilen WChOA-UMD varyantlarının neredeyse tüm deneylerde diğer yaklaşımları geride bıraktığını göstermektedir.

Özellikle:


- $maxFEs = 500 \times m$ için, WChOA ve WChOA-UMD, 60 deneyin 46'sında daha yüksek amaç fonksiyonu değerleri elde etmiştir.
- $maxFEs = 1000 \times m$ için, 60 deneyin 48'inde daha iyi performans göstermişlerdir.
- Bu deneyler arasında WChOA-UMD algoritması, $maxFEs = 500 \times m$ için 38 deneyde ve $maxFEs = 1000 \times m$ için 37 deneyde en iyi amaç fonksiyonu değerlerini sağlamıştır.

DeneySEL sonuçlar, WChOA-UMD algoritmasının diğer yöntemlere kıyasla daha dengeli bir arama yeteneğine sahip olduğunu göstermektedir. Farklı eşik seviyelerinde çok seviyeli görüntü segmentasyonunda optimal çözüme daha iyi bir şekilde yakınsamakta ve değişken karmaşıklıkta problemleri etkili bir şekilde çözmektedir. Ayrıca, bu bulgular önerilen algoritmanın renkli görüntü segmentasyonu alanında uygulanabilirliğini vurgulamaktadır.

3.3.6. PSNR, SSIM ve FSIM Kullanılarak Performans Değerlendirme

Bu bölümde, önerilen yöntem ve rakip algoritmaların çok seviyeli görüntü segmentasyonu performansını değerlendirmek için PSNR, SSIM ve FSIM metrikleri kullanılmıştır. 16 algoritma, 10 test görüntüsü, 6 farklı eşik seviyesi, 2 eşikleme fonksiyonu ve 2 sonlandırma kriteri için elde edilen detaylı PSNR, SSIM ve FSIM değerleri, okunabilirliği artırmak amacıyla Ek'te sunulmuştur. Bunun yerine, bu bölümde farklı eşik seviyeleri, eşikleme fonksiyonları ve sonlandırma kriterlerine göre her bir algoritma için ortalama PSNR, SSIM ve FSIM değerlerinin grafiksel gösterimleri verilmiştir.


Otsu yöntemi ve Kapur entropisi için ($maxFEs = 500 \times m$ ve $maxFEs = 1000 \times m$ olmak üzere) her iki sonlandırma kriterini dikkate alan ortalama PSNR değerleri Şekil 10'da gösterilmiştir. Şekil, 10 test görüntüsü için değişen eşik seviyelerine göre PSNR eğilimlerini ortaya koymaktadır. Sonuçlar, ilk kez görüntü segmentasyonunda uygulanan WChOA algoritması ile önerilen varyantlarının, tüm eşik seviyelerinde diğer algoritmalarla kıyasla daha yüksek PSNR değerleri elde ettiğini göstermektedir. PSNR, görüntü bozulmasını ölçmek ve görüntü kalitesini değerlendirmek için kullanılır; daha yüksek bir PSNR değeri, daha düşük bozulma ve daha iyi segmentasyonu ifade eder. Elde edilen sonuçlara göre, önerilen yöntem, diğer yaklaşımlara kıyasla görüntü segmentasyonu konusunda başarılı bir performans sergilemektedir.



Şekil 10. Ortalama PSNR değerleri (Otsu 500: $maxFEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $maxFEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $maxFEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $maxFEs = 1000 \times m$ için Kapur entropisi)

SSIM orijinal ve segmente edilmiş görüntüler arasındaki görsel benzerliği değerlendirmek için önemli bir metriktir. SSIM, kontrast, parlaklık ve yapısal bilgileri dikkate alarak segmente edilmiş görüntünün orijinal görüntünün temel özelliklerini ne kadar iyi koruduğunu değerlendirir. Daha yüksek bir SSIM değeri, segmente edilmiş görüntü ile orijinal görüntü arasında daha fazla benzerlik olduğunu gösterir. Ayrıca, eşik seviyelerinin

sayısı arttıkça SSIM değerleri de artar; bu, segmente edilmiş görüntülerin orijinal görüntülere daha çok benzediği ve daha doğru nesne çıkarma imkanı sağladığı anlamına gelir. Otsu yöntemi ve Kapur entropisi için farklı sonlandırma kriterlerine ($maxFEs= 500 \times m$ ve $maxFEs= 1000 \times m$) ve eşik seviyelerine göre ortalama SSIM değerleri Şekil 11'de gösterilmiştir. Şekil, 11 test görüntüleri için SSIM eğilimlerini sunmakta olup, WChOA algoritmasının ve önerilen WChOA-UMD varyantının neredeyse tüm eşik seviyelerinde daha yüksek SSIM değerleri elde ettiğini göstermektedir.




Şekil 11. Ortalama SSIM değerleri (Otsu 500: $maxFEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $maxFEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $maxFEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $maxFEs = 1000 \times m$ için Kapur entropisi)

FSIM indeksi, orijinal ve segmente edilmiş görüntüler arasındaki özellik benzerliğini değerlendirmede önemli bir metriktir. FSIM insan görsel sisteminin görüntülerin yorumlanmasında öncelikle düşük seviyeli özelliklere dayandığı ilkesine dayanır. Daha yüksek bir FSIM değeri, iki görüntü arasında daha fazla benzerlik olduğunu gösterir ve eşik seviyelerinin sayısı arttıkça FSIM değerleri de genellikle yükselmekte, bu da segmentasyon doğruluğundaki iyileşmeyi işaret etmektedir.

Otsu yöntemi ve Kapur entropisi için farklı sonlandırma kriterlerine ($maxFEs= 500 \times m$ ve $maxFEs= 1000 \times m$) ve eşik seviyelerine göre ortalama FSIM değerleri Şekil 12'de

gösterilmiştir. Şekil, 12 test görüntüsü için FSIM eğilimlerini sunmakta olup, WChOA algoritması ve WChOA-UMD varyantının neredeyse tüm eşik seviyelerinde daha yüksek FSIM değerleri elde ettiğini vurgulamaktadır.




Şekil 12. Ortalama FSIM değerleri (Otsu 500: $\max FEs = 500 \times m$ için otsu yöntemi, Otsu 1000: $\max FEs = 1000 \times m$ için Otsu yöntemi, Kapur 500: $\max FEs = 500 \times m$ için Kapur entropisi, Kapur 1000: $\max FEs = 1000 \times m$ için Kapur entropisi)

Tablo 17. En iyi Friedman puanlarına sahip algoritmalar

Uygunluk Fonksiyonu	$\max FEs$	Eşik seviyeleri (m)					
		2	4	6	8	10	12
Otsu yöntemi	500	Durum-2	Durum -2	Durum -7	Durum -8	Durum -7	Durum -8
	1000	WChOA	Durum -1	Durum -2	Durum -8	Durum -1	Durum -8
Kapur entropisi	500	Durum -8	Durum -2	Durum -7	Durum -8	Durum -2	Durum -1
	1000	Durum -2	Durum -7	Durum -8	Durum -2	Durum -4	Durum -4

Algoritma performansını değerlendirmek için Friedman sıralama puanları kullanılmıştır. Bu puanlara göre en başarılı algoritmalar Tablo 17'de özetlenmiştir ve tablo, önerilen yöntemin çeşitli segmentasyon koşullarında elde ettiği başarıyı vurgulamaktadır.





Görsel karşılaştırma için, Şekil 13–16, Tablo 17'de listelenen en iyi algoritmalara ait segmente görüntüleri sunmakta olup, önerilen yöntemin farklı eşik seviyeleri, eşikleme teknikleri ve sonlandırma kriterleri altında etkinliğini göstermektedir.

I	m=2	m=4	m=6	m=8	m=10	m=12
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						

Şekil 13. Otsu yöntemi ve $maxFEs = 500 \times m$ için segmentasyon sonuçları

I	m=2	m=4	m=6	m=8	m=10	m=12
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						

Şekil 14. Otsu yöntemi ve $maxFEs = 1000 \times m$ için segmentasyon sonuçları

I	m=2	m=4	m=6	m=8	m=10	m=12
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						

Şekil 15. Kapur entropisi ve $maxFEs = 500 \times m$ için segmentasyon sonuçları

I	m=2	m=4	m=6	m=8	m=10	m=12
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						

Şekil 16. Kapur entropisi ve $maxFEs = 1000 \times m$ için segmentasyon sonuçları

4. SONUÇLAR

Bu tez çalışmasında, birkaç farklı optimizasyon yaklaşımı tanıtmaktadır: MFO-PSO, MFO-SSA, MFO-PSO-SSA ve WChOA-UMD. Önerilen yöntemler kıyaslama fonksiyonları ve görüntüler üzerinde kapsamlı bir performans değerlendirmesiyle test edilmiştir.

Çok aşamalı hibrit algoritmaların performansı (MFO-PSO, MFO-SSA, MFO-PSO-SSA), 100 görüntü üzerinde $m = 2, 4, 6$ ve 8 eşik seviyelerinde $\text{maxFEs} = 500 \times m$ durdurma koşulu altında değerlendirilmiştir. Hem Kapur entropisi hem de Otsu yöntemi amaç fonksiyonu olarak kullanılmıştır. Analizler, Otsu yöntemi için MFO-PSO-SSA algoritmasının düşük ve orta düzeyde eşikleme senaryolarında ($m = 2, 4$ ve 6) daha başarılı bir performans sergilediğini göstermektedir. Özellikle, $m = 2$ gibi düşük eşik seviyelerinde önerilen üç algoritmanın Friedman puanları neredeyse özdeştir. Ancak, eşik seviyeleri yükseldikçe (örneğin $m = 8$), MFO-PSO ve MFO-SSA algoritmalarının performanslarının daha rekabetçi olduğu gözlenmiştir.

Kapur entropisi kullanıldığında, MFO-PSO-SSA algoritması genel olarak en iyi sonuçları verirken, Otsu yöntemi altında MFO-SSA algoritması sürekli olarak daha iyi performans sağlamıştır. MFO-PSO ise, özellikle yüksek eşik seviyelerinde ikinci sırada yer almıştır. Bu bulgular, önerilen hibrit algoritmaların farklı amaç fonksiyonlarına göre uyarlanabilirliğini ve çeşitli eşikleme senaryolarında etkili bir şekilde çalışabildiğini göstermektedir. Ayrıca, bu algoritmaların değerlendirilen diğer meta sezgisel yaklaşımlar arasında daha yüksek performans sergilediği görülmüştür.

Bu çalışmada ayrıca, optimizasyon performansını artırmak amacıyla tasarlanmış yeni bir meta sezgisel arama algoritması olan WChOA-UMD tanıtılmıştır. Algoritma, IEEE CEC 2020 setinden alınan 10 kıyaslama fonksiyonu kullanılarak değerlendirilmiştir. Friedman ve Wilcoxon istatistiksel testleriyle gerçekleştirilen analizler, WChOA-UMD'nin tüm kıyaslama fonksiyonlarında temel WChOA algoritmasından daha başarılı performans sergilediğini ortaya koymuştur.

UMD'nin farklı varyantları arasından en etkili sekiz tanesi seçilerek ileri testler gerçekleştirilmiştir. Görüntü segmentasyonu uygulamalarında, WChOA-UMD'nin farklı eşikleme fonksiyonları, eşik seviyeleri ve sonlandırma kriterleri altında temel algoritma ve rakip yöntemlere kıyasla daha üstün performans gösterdiği tespit edilmiştir. Özellikle,

yüksek PSNR, SSIM ve FSIM değerleri, yöntemin renkli görüntü segmentasyonunda etkinliğini ve değişken karmaşıklıkta problemler karşısında dengeli bir arama yeteneği sergilediğini doğrulamıştır. Durum 1, 2, 4, 7 ve 8 varyantları, en başarılı performans gösterenler olarak öne çıkmıştır. UMD'nin WChOA ile entegrasyonu, algoritmanın sağlamlığını, uyum yeteneğini, yakınsama hızını ve genel çözüm kalitesini önemli ölçüde artırmıştır. Bu sayede, dinamik optimizasyon ortamlarında daha etkili bir çözüm sunulmuştur.



5. ÖNERİLER

Bu çalışmada geliştirilen WChOA-UMD ve MFO-PSO-SSA algoritmaları, çok seviyeli eşiklemeye dayalı segmentasyon problemlerinde umut verici sonuçlar sunmuştur. Ancak, bu algoritmaların potansiyelini daha da geliştirmek ve farklı uygulama alanlarında test etmek için aşağıdaki çalışmalar yapılabilir:

- Algoritmaların Karşılaştırılması: WChOA-UMD ve MFO-PSO-SSA'nın birbirleriyle ve farklı meta-sezgisel yöntemlerle karşılaştırılması, her bir yaklaşımın avantajlarını ve sınırlamalarını ortaya çıkaracaktır. Özellikle farklı eşikleme seviyeleri ve amaç fonksiyonları altında performans analizi yapılmalıdır.
- Veri Setlerinin Genişletilmesi: Her iki algoritma tıbbi görüntü (örneğin MRI veya CT), uydu görüntüleri, termal görüntüler ve video işleme gibi daha geniş ve çeşitli veri setleri üzerinde test edilebilir. Bu, özellikle gerçek dünya senaryolarında algoritmaların sağlamlığını değerlendirmek açısından önemlidir.
- Hibrit Yapının İyileştirilmesi: MFO-PSO-SSA farklı kombinasyonlarla (örneğin MFO-GWO veya PSO-SSA) test edilebilir ve en etkili yapıyı belirlemek için daha fazla analiz yapılabilir. Ayrıca, çok yüksek eşik seviyelerinde performans düşüşünün önüne geçmek için algoritma stratejisi iyileştirilebilir.
- Uygulama Alanlarının Çeşitlendirilmesi: Her iki algoritma görüntü segmentasyonu dışında, özellik seçimi, sinir ağı optimizasyonu, enerji dağıtımı, finansal modelleme ve mühendislik tasarım optimizasyonu gibi farklı alanlara uygulanabilir.
- Gerçek Zamanlı Uygulamalar: Özellikle MFO-PSO-SSA'nın gerçek zamanlı sistemlerde (örneğin video işleme, dron navigasyonu veya otonom araçlar) uygulanabilirliği araştırılabilir. WChOA-UMD ise tıbbi teşhis, tarım ve güvenlik gibi alanlarda daha kapsamlı test edilebilir.
- Paralel Hesaplama ve Hızlandırılmış Yaklaşım: Algoritmaların hesaplama karmaşıklığını azaltmak için paralel hesaplama teknikleri kullanılarak hızlandırılması değerlendirilebilir.

Bu öneriler, WChOA-UMD ve MFO-PSO-SSA algoritmasının optimizasyon performansının artırılmasını ve farklı disiplinlerdeki uygulamalar için daha güçlü bir araç haline gelmesini sağlayabilir. Detaylı çalışmalarla bu yöntemlerin hem teorik hem de pratik katkıları güçlendirilebilir.

6. KAYNAKLAR

- Abdelrazek, M., Abd Elaziz, M., & El-Baz, A. (2024). CDMO: Chaotic Dwarf Mongoose optimization algorithm for feature selection. *Scientific reports*, 14(1), 701.
- Abualigah, L., Al-Okbi, N. K., Elaziz, M. A., & Houssein, E. H. (2022). Boosting marine predators algorithm by salp swarm algorithm for multilevel thresholding image segmentation. *Multimedia tools and applications*, 81(12), 16707-16742.
- Agrawal, S., Panda, R., Choudhury, P., & Abraham, A. (2022). Dominant color component and adaptive whale optimization algorithm for multilevel thresholding of color images. *Knowledge-Based Systems*, 240, 108172.
- Akan, T., Oliva, D., Feizi-Derakhshi, A.-R., Feizi-Derakhshi, A.-R., Perez-Cisneros, M., & Bhuiyan, M. A. (2024). Battle royale optimizer for multilevel image thresholding. *The Journal of Supercomputing*, 80(4), 5298-5340.
- Akay, R., Saleh, R. A., Farea, S. M., & Kanaan, M. (2022). Multilevel thresholding segmentation of color plant disease images using metaheuristic optimization algorithms. *Neural Computing and Applications*, 34(2), 1161-1179.
- Bhandari, A. K., Kumar, A., & Singh, G. K. (2015). Modified artificial bee colony based computationally efficient multilevel thresholding for satellite image segmentation using Kapur's, Otsu and Tsallis functions. *Expert systems with applications*, 42(3), 1573-1601.
- Cheng, M.-Y., & Prayogo, D. (2014). Symbiotic organisms search: a new metaheuristic optimization algorithm. *Computers & Structures*, 139, 98-112.
- Dehghani, M., Montazeri, Z., Trojovská, E., & Trojovský, P. (2023). Coati Optimization Algorithm: A new bio-inspired metaheuristic algorithm for solving optimization problems. *Knowledge-Based Systems*, 259, 110011.
- Eisham, Z. K., Haque, M. M., Rahman, M. S., Nishat, M. M., Faisal, F., & Islam, M. R. (2023). Chimp optimization algorithm in multilevel image thresholding and image clustering. *Evolving Systems*, 14(4), 605-648.
- Gad, A. G. (2022). Particle swarm optimization algorithm and its applications: a systematic review. *Archives of computational methods in engineering*, 29(5), 2531-2561.
- Gandomi, A. H., Yang, X.-S., & Alavi, A. H. (2013). Cuckoo search algorithm: a metaheuristic approach to solve structural optimization problems. *Engineering with computers*, 29, 17-35.
- Gharehchopogh, F. S., & Ibrikci, T. (2024). An improved African vultures optimization algorithm using different fitness functions for multi-level thresholding image segmentation. *Multimedia Tools and Applications*, 83(6), 16929-16975.

- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872.
- Holland, J. (1975). An introductory analysis with applications to biology, control, and artificial intelligence. *Adaptation in Natural and Artificial Systems. First Edition, The University of Michigan, USA*.
- Houssein, E. H., Abdalkarim, N., Hussain, K., & Mohamed, E. (2024). Accurate multilevel thresholding image segmentation via oppositional Snake Optimization algorithm: Real cases with liver disease. *Computers in Biology and Medicine*, 169, 107922.
- Houssein, E. H., Abdelkareem, D. A., Emam, M. M., Hameed, M. A., & Younan, M. (2022). An efficient image segmentation method for skin cancer imaging using improved golden jackal optimization algorithm. *Computers in Biology and Medicine*, 149, 106075.
- Houssein, E. H., Mohamed, G. M., Ibrahim, I. A., & Wazery, Y. M. (2023). An efficient multilevel image thresholding method based on improved heap-based optimizer. *Scientific Reports*, 13(1), 9094.
- Kaabneh, K., AbuFalahah, I., Eguchi, K., Gochhait, S., Leonova, I., Montazeri, Z., & Dehghani, M. (2024). Dollmaker Optimization Algorithm: A Novel Human-Inspired Optimizer for Solving Optimization Problems. *International Journal of Intelligent Engineering & Systems*, 17(3).
- Kahraman, H. T., Aras, S., & Gedikli, E. (2020). Fitness-distance balance (FDB): a new selection method for meta-heuristic search algorithms. *Knowledge-Based Systems*, 190, 105169.
- Kang, X., & Hua, C. (2023). Multilevel thresholding image segmentation algorithm based on Mumford--Shah model. *Journal of Intelligent Systems*, 32(1), 20220290.
- Kapur, J. N., Sahoo, P. K., & Wong, A. K. (1985). A new method for gray-level picture thresholding using the entropy of the histogram. *Computer vision, graphics, and image processing*, 29(3), 273-285.
- Khishe, M., & Mosavi, M. R. (2020). Chimp optimization algorithm. *Expert systems with applications*, 149, 113338.
- Khishe, M., Nezhadshahbodaghi, M., Mosavi, M. R., & Martín, D. (2021). A weighted chimp optimization algorithm. *IEEE Access*, 9, 158508--158539.
- Kumar, A., Kumar, A., Vishwakarma, A., & Singh, G. K. (2022). Multilevel thresholding for crop image segmentation based on recursive minimum cross entropy using a swarm-based technique. *Computers and Electronics in Agriculture*, 203, 107488.
- Lang, Y., & Gao, Y. (2025). Dream Optimization Algorithm (DOA): A novel metaheuristic optimization algorithm inspired by human dreams and its applications to real-world engineering problems. *Computer Methods in Applied Mechanics and Engineering*, 436, 117718.

- Liu, Q., Li, N., Jia, H., Qi, Q., & Abualigah, L. (2023). A chimp-inspired remora optimization algorithm for multilevel thresholding image segmentation using cross entropy. *Artificial Intelligence Review*, 56, 159-216.
- Mirjalili, S. (2015). Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm. *Knowledge-based systems*, 89, 228-249.
- Mirjalili, S. (2016). SCA: a sine cosine algorithm for solving optimization problems. *Knowledge-based systems*, 96, 120-133.
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., & Mirjalili, S. M. (2017). alp Swarm Algorithm: A bio-inspired optimizer for engineering design problems. *Advances in engineering software*, 114, 163-191.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- Orujpour, M., Feizi-Derakhshi, M.-R., & Akan, T. (2023). A multimodal butterfly optimization using fitness-distance balance. *Soft Computing*, 27(23), 17909-17922.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica*, 11(285-296), 23-27.
- Ozkaya, B., Guvenc, U., & Bingol, O. (2022). Fitness Distance Balance based LSHADE algorithm for energy hub economic dispatch problem. *IEEE Access*, 10, 66770-66796.
- Pare, S., Kumar, A., Bajaj, V., & Singh, G. K. (2017). An efficient method for multilevel color image thresholding using cuckoo search algorithm based on minimum cross entropy. *Applied Soft Computing*, 61, 570-592.
- Poli, R., Kennedy, J., & Blackwell, T. (2007). Particle swarm optimization: An overview. *Swarm intelligence*, 1, 33-57.
- Qiao, L., Liu, K., Xue, Y., Tang, W., & Salehnia, T. (2024). A multi-level thresholding image segmentation method using hybrid Arithmetic Optimization and Harris Hawks Optimizer algorithms. *Expert Systems with Applications*, 241, 122316.
- Qiao, Z., Wu, L., Heidari, A. A., Zhao, X., & Chen, H. (2025). An enhanced tree-seed algorithm for global optimization and neural architecture search optimization in medical image segmentation. *Biomedical Signal Processing and Control*, 104, 107457.
- Renugambal, A., Bhuvaneswari, K. S., & Tamilarasan, A. (2023). Hybrid SCCSA: An efficient multilevel thresholding for enhanced image segmentation. *Multimedia Tools and Applications*, 32711-32753.
- Sezgin, M., & Sankur, B. L. (2004). Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic imaging*, 13(1), 146-168.

- Sharma, A., Chaturvedi, R., & Bhargava, A. (2022). A novel opposition based improved firefly algorithm for multilevel image segmentation. *Multimedia Tools and Applications*, 81(11), 15521-15544.
- Storn, R., & Price, K. (1997). Differential evolution--a simple and efficient heuristic for global optimization over continuous spaces. *Journal of global optimization*, 11, 341-359.
- Su, H., Zhao, D., Yu, F., Heidari, A. A., Zhang, Y., Chen, H., . . . Quan, S. (2022). Horizontal and vertical search artificial bee colony for image segmentation of COVID-19 X-ray images. *Computers in Biology and Medicine*, 142, 105181.
- Suresh, S., & Lal, S. (2016). An efficient cuckoo search algorithm based multilevel thresholding for segmentation of satellite images using different objective functions. *Expert Systems with Applications*, 58, 184-209.
- Swain, M., Tripathy, T. T., Panda, R., Agrawal, S., & Abraham, A. (2022). Differential exponential entropy-based multilevel threshold selection methodology for colour satellite images using equilibrium-cuckoo search optimizer. *Engineering Applications of Artificial Intelligence*, 109, 104599.
- Tan, Z., Li, K., & Wang, Y. (2021). An improved cuckoo search algorithm for multilevel color image thresholding based on modified fuzzy entropy. *Journal of Ambient Intelligence and Humanized Computing*, 1-14.
- Tang, Z., Tao, S., Wang, K., Lu, B., Todo, Y., & Gao, S. (2022). Chaotic wind driven optimization with fitness distance balance strategy. *International Journal of Computational Intelligence Systems*, 15(1), 46.
- Thomas, E., & Kumar, S. (2023). Harris Hawks Optimization-Based Multilevel Thresholding Segmentation of Magnetic Resonance Brain Images. *International Conference on Communication, Devices and Computing* (s. 309-322). Springer.
- Wang, C., Tu, C., Wei, S., Yan, L., & Wei, F. (2023). MSWOA: A mixed-strategy-based improved whale optimization algorithm for multilevel thresholding image segmentation. *Electronics*, 12(12), 2698.
- Wang, W., Ye, C., Pan, Z., & Tian, J. (2025). Multilevel threshold segmentation of rice plant images utilizing tuna swarm optimization algorithm incorporating quadratic interpolation and elite swarm genetic operators. *Expert Systems with Applications*, 263, 125673.
- Wang, Z., Mo, Y., Cui, M., Hu, J., & Lyu, Y. (2023). An improved golden jackal optimization for multilevel thresholding image segmentation. *PloS one*, 18(5), e0285211.
- Yılmaz, A. G., & Alsamoua, S. (2025). Meta sezgisel arama algoritmalarının çok seviyeli görüntü eşikleme performanslarının karşılaştırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14(1), 1-1.

- Yue, C., Price, K., Suganthan, P., Liang, J., Ali, M., Qu, B., . . . Partha, P. (2020). *Biswas Problem Definitions and Evaluation Criteria for the CEC 2020 Special Session and Competition on Single Objective Bound Constrained Numerical Optimization*. Technical Report, Computational Intelligence Laboratory. Zhengzhou China: Zhengzhou University.
- Zhang, J., Zhang, G., Kong, M., & Zhang, T. (2024). SCGJO: A hybrid golden jackal optimization with a sine cosine algorithm for tackling multilevel thresholding image segmentation. *Multimedia Tools and Applications*, 83(3), 7681-7719.
- Zheng, K., Yuan, X., Xu, Q., Dong, L., Yan, B., & Chen, K. (2022). Hybrid particle swarm optimizer with fitness-distance balance and individual self-exploitation strategies for numerical optimization problems. *Information Sciences*, 608, 424-452.
- <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/> BSDS300-images.
- URL-1. (2003, Ekim 13). Veri Setimiz: <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/BSDS300/html/dataset/images.html> adresinden alınmıştır.

7. EKLER

Ek Tablo 1. Otsu yöntemi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=500 \times m$)

m	l	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	2737,074	2725,243	2743,743	2739,341	2737,367	2735,023	2742,085	2752,066	2748,824	2758,227	2742,976	2746,675	2741,095	2733,923	2743,837	2744,737
	2	1546,111	1542,659	1543,179	1550,087	1549,543	1542,648	1550,242	1558,874	1562,89	1560,921	1557,5	1556,029	1555,361	1545,926	1557,683	1558,725
	3	2045,823	2048,159	2052,438	2055,056	2056,045	2058,083	2056,986	2063,669	2069,752	2060,543	2064,757	2063,925	2063,697	2062,156	2060,129	2064,917
	4	3751,211	3750,514	3746,45	3755,181	3745,171	3753,348	3750,586	3768,945	3767,619	3769,786	3772,374	3767,559	3767,873	3765,901	3764,98	3769,406
	5	6543,776	6539,734	6556,53	6553,129	6548,085	6555,473	6550,013	6572,956	6572,608	6573,75	6572,767	6565,286	6563,162	6564,433	6576,648	6566,533
	6	3410,207	3432,674	3433,317	3432,827	3422,742	3432,178	3426,886	3432,669	3437,171	3438,64	3422,988	3429,121	3427,679	3425,944	3429,048	3430,714
	7	2001,345	1992,559	2006,84	2006,68	2006,063	2002,733	2008,456	2014,906	2011,195	2009,464	2015,995	2010,7	2010,275	2009,741	2005,913	2016,538
	8	1332,685	1325,152	1328,754	1339,794	1332,781	1337,124	1338,239	1346,524	1349,764	1346,32	1349,134	1348,85	1341,322	1345,048	1346,207	1349,081
	9	3078,593	3086,274	3090,238	3097,18	3090,702	3088,602	3096,844	3108,937	3099,905	3107,093	3096,787	3099,8	3099,324	3099,298	3095,716	3097,638
	10	1525,829	1500,797	1526,837	1531,625	1508,113	1522,823	1522,144	1532,401	1532,89	1529,045	1523,838	1524,909	1533,122	1526,415	1530,328	1529,312
4	1	2971,224	2983,725	2978,576	2979,185	2982,445	2979,029	2979,672	2980,495	2985,098	2983,454	2978,855	2984,145	2983,573	2982,657	2983,677	2985,035
	2	1685,928	1685,786	1690,94	1690,277	1690,988	1684,644	1691,281	1691,914	1692,159	1694,731	1693,811	1690,774	1695,597	1688,21	1690,137	1691,956
	3	2237,984	2233,492	2242,192	2236,82	2242,401	2238,648	2242,114	2246,91	2251,695	2247,267	2243,703	2246,085	2245,638	2245,366	2242,789	2247,555
	4	3907,647	3904,117	3915,465	3916,674	3905,069	3911,686	3916,22	3916,376	3916,036	3920,918	3919,852	3918,136	3920,576	3913,992	3920,143	3919,481
	5	6850,046	6856,642	6856,163	6861,359	6856,216	6858,982	6857,505	6865,578	6864,933	6866,469	6862,937	6863,268	6860,461	6854,138	6860,196	6863,986
	6	3626,963	3621,681	3635,886	3629,191	3635,181	3634,584	3630,871	3639,573	3631,285	3632,235	3639,309	3630,197	3634,974	3633,786	3636,253	3640,083
	7	2215,266	2220,331	2228,699	2224,114	2233,559	2220,861	2220,534	2226,323	2229,603	2222,014	2222,431	2225,457	2223,379	2229,035	2230,55	2221,228
	8	1458,24	1460,839	1466,011	1461,55	1462,692	1461,551	1465,346	1466,807	1462,093	1463,385	1462,209	1464,689	1467,757	1458,666	1468,058	1461,075
	9	3326,803	3329,522	3340,704	3340,955	3336,021	3336,222	3341,613	3342,281	3338,818	3350,156	3340,224	3340,15	3335,643	3334,665	3344,094	3341,944
	10	1731,037	1725,522	1732,67	1728,978	1733,961	1735,643	1739,335	1735,071	1740,234	1731,957	1731,666	1737,891	1736,247	1739,74	1742,006	1746,334
6	1	3055,786	3062,076	3062,298	3059,377	3060,01	3057,887	3059,611	3067,026	3062,175	3065,018	3060,077	3061,563	3064,167	3064,047	3062,819	3064,734
	2	1739,541	1736,057	1743,046	1740,114	1740,816	1740,505	1738,122	1740,503	1741,137	1739,936	1742,39	1743,033	1736,743	1738,72	1741,42	1740,668
	3	2300,056	2297,708	2301,462	2302,265	2304,24	2302,317	2301,682	2302,744	2305,403	2307,668	2305,133	2306,693	2300,929	2308,062	2307,642	2305,348
	4	3968,216	3966,064	3970,711	3969,996	3965,829	3967,566	3967,846	3973,705	3969,814	3968,732	3970,132	3970,526	3969,221	3968,834	3971,435	3967,14
	5	6944,81	6946,51	6949,056	6948,293	6953,987	6950,394	6951,48	6952,411	6953,982	6951,883	6950,96	6948,6	6952,184	6948,545	6956,471	6952,526
	6	3703,885	3707,077	3707,834	3702,849	3706,919	3709,819	3706,175	3709,408	3707,619	3709,916	3710,537	3707,324	3708,627	3710,73	3709,275	3708,092
	7	2303,496	2297,185	2304,373	2304,355	2303,958	2303,739	2301,594	2304,913	2303,75	2302,027	2305,436	2303,754	2306,8	2305,37	2298,706	2307,224
	8	1505,397	1507,466	1512,165	1512,44	1509,612	1511,83	1509,776	1513,262	1511,194	1508,625	1512,027	1510,219	1511,149	1511,152	1511,32	1511,749
	9	3419,025	3421,206	3424,437	3422,984	3426,666	3422,367	3422,771	3427,851	3429,736	3427,156	3424,266	3425,246	3427,52	3424,029	3427,858	3428,033
	10	1792,242	1791,979	1796,248	1797,419	1794,984	1792,366	1796,761	1795,846	1794,564	1800,367	1797,849	1794,258	1795,875	1797,854	1795,282	1794,056
8	1	3095,035	3094,788	3100,935	3100,012	3103,595	3099,656	3100,506	3098,546	3104,124	3100,637	3098,626	3099,479	3101,677	3101,74	3104,208	3100,35
	2	1763,523	1763,879	1764,596	1764,643	1767,469	1768,115	1764,392	1768,653	1768,017	1767,328	1765,518	1765,958	1766,287	1767,216	1765,996	1768,691
	3	2330,243	2332,263	2334,553	2333,814	2333,914	2335,018	2334,367	2335,825	2332,99	2335,402	2335,729	2334,178	2333,14	2335,624	2334,013	2334,405

Ek Tablo 1'in devamı

	4	3993,417	3994,206	3993,94	3994,909	3993,251	3997,008	3996,942	3999,81	3998,207	3999,083	3997,443	3997,645	3995,869	3994,276	3996,613	3998,257
	5	6992,46	6994,43	6995,409	6994,536	6995,865	6997,45	6995,604	6993,495	6997,185	6993,848	6994,644	6996,019	6993,927	6996,418	6997,189	6997,663
	6	3742,932	3738,304	3742,176	3745,083	3744,734	3747,146	3742,216	3742,347	3742,419	3739,728	3744,674	3744,946	3742	3747,931	3745,343	3743,693
	7	2341,433	2337,658	2341,707	2340,95	2342,599	2343,816	2343,457	2341,77	2341,306	2345,089	2340,648	2341,969	2341,934	2339,032	2341,941	2343,293
	8	1532,37	1533,489	1533,219	1532,896	1535,076	1534,259	1536,2	1536,904	1535,819	1536,228	1536,754	1536,637	1533,963	1533,872	1534,513	1535,599
	9	3462,031	3461,852	3464,573	3466,318	3461,814	3462,475	3464,669	3461,062	3465,976	3463,881	3465,466	3463,109	3465,688	3463	3464,724	3463,39
	10	1823,205	1822,047	1825,318	1822,844	1823,57	1826,354	1823,671	1823,238	1824,776	1823,024	1824,77	1824,682	1823,968	1822,874	1824,185	1823,903
10	1	3121,272	3120,716	3121,541	3122,446	3121,88	3123,461	3121,707	3122,548	3123,24	3124,93	3122,275	3123,788	3123,813	3122,623	3125,303	3124,233
	2	1780,889	1779,301	1780,672	1781,553	1781,717	1779,962	1780,486	1782,688	1780,872	1781,24	1781,569	1781,722	1779,26	1782,714	1781,475	1782,744
	3	2349,223	2347,22	2349,941	2349,661	2350,596	2351,171	2349,778	2352,851	2350,929	2352,054	2350,112	2351,156	2351,022	2351,174	2352,244	2351,718
	4	4010,342	4010,753	4012,625	4011,558	4012,929	4012,716	4013,307	4013,326	4012,187	4011,648	4014,059	4013,29	4010,777	4012,077	4013,891	4013,239
	5	7016,677	7017,247	7018,761	7019,45	7020,418	7018,466	7019,57	7020,04	7018,951	7019,892	7019,9	7020,678	7020,031	7018,165	7020,202	7018,861
	6	3764,082	3767,565	3766,572	3765,698	3764,905	3764,871	3768,077	3764,142	3765,857	3764,868	3766,76	3766,391	3765,913	3764,814	3766,928	3765,589
	7	2363,542	2361,786	2366,986	2365,115	2365,012	2365,636	2365,319	2367,344	2366,109	2364,133	2365,797	2366,46	2362,534	2368,323	2364,999	2365,382
	8	1549,772	1546,985	1550,604	1550,507	1550,854	1551,823	1548,698	1552,82	1551,89	1549,949	1550,952	1549,48	1551,613	1549,012	1551,665	1550,676
	9	3482,569	3485,255	3485,294	3486,925	3486,103	3485,139	3485,89	3487,332	3485,683	3485,421	3484,755	3487,011	3486,388	3484,586	3486,593	3485,943
	10	1841,121	1839,201	1841,381	1841,749	1840,399	1840,823	1839,551	1840,796	1840,817	1840,762	1839,598	1838,908	1839,984	1839,928	1839,385	1842,901
12	1	3136,007	3137,837	3137,857	3136,9	3138,668	3138,144	3137,766	3139,396	3137,933	3137,861	3136,487	3137,712	3137,715	3137,082	3138,769	3138,984
	2	1788,918	1789,947	1789,865	1791,464	1790,576	1790,157	1790,615	1791,131	1791,84	1791,068	1789,69	1791,593	1790,929	1791,854	1791,904	1791,554
	3	2358,881	2360,723	2360,519	2361,172	2361,73	2361,348	2362,522	2363,326	2362,441	2363,241	2362,423	2361,651	2361,495	2361,488	2362,595	2361,647
	4	4021,542	4021,101	4023,276	4023,616	4021,452	4022,395	4023,176	4023,792	4022,839	4021,872	4022,023	4023,028	4023,627	4022,798	4024,05	4024,98
	5	7031,876	7033,484	7033,18	7035,353	7032,047	7035,917	7034,202	7032,981	7034,485	7033,429	7033,632	7032,504	7033,894	7034,956	7033,989	7033,885
	6	3778,532	3779,473	3779,162	3779,449	3779,565	3779,341	3778,395	3780,279	3778,271	3778,942	3778,744	3779,472	3778,63	3777,83	3780,363	3779,821
	7	2378,585	2378,113	2379,155	2379,194	2381,583	2381,161	2379,665	2379,437	2379,498	2381,203	2380,351	2378,184	2379,641	2380,059	2381,388	2379,248
	8	1557,726	1559,154	1560,626	1560,37	1559,783	1560,107	1561,226	1561,398	1558,858	1560,875	1560,791	1560,69	1560,379	1561,393	1561,181	1559,775
	9	3499,918	3500,526	3500,897	3501,652	3501,318	3499,199	3500,579	3500,413	3499,358	3500,897	3501,214	3500,387	3501,753	3499,855	3501,595	3500,624
	10	1848,916	1850,436	1851,596	1851,921	1851,159	1851,458	1852,321	1852,37	1851,271	1850,858	1851,481	1852,153	1851,102	1850,839	1850,91	1849,552

Ek Tablo 2. Otsu yöntemi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=1000 \times m$)

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	2728,046	2736,835	2735,819	2738,899	2732,252	2743,27	2748,984	2750,304	2751,112	2753,223	2751,062	2744,249	2744,117	2748,843	2751,934	2748,661
	2	1541,264	1543,551	1553,007	1542,008	1546,289	1544,833	1547,862	1566,518	1560	1564,981	1558,983	1562,899	1558,124	1554,514	1559,679	1562,125
	3	2045,685	2039,071	2055,435	2049,221	2054,039	2053,009	2052,089	2069,108	2071,535	2065,321	2063,702	2070,788	2062,614	2067,042	2064,544	2064,917
	4	3748,363	3747,132	3756,105	3763,88	3756,725	3758,588	3761,66	3777,123	3769,923	3765,023	3771,937	3766,127	3764,552	3764,588	3767,747	3772,434
	5	6538,647	6541,102	6548,044	6554,843	6551,463	6560,329	6562,061	6577,023	6574,494	6572,791	6561,217	6567,042	6566,947	6568,381	6573,875	6575,547
	6	3418,88	3428,078	3425,07	3424,068	3423,448	3437,035	3431,321	3433,769	3434,632	3425,304	3442,465	3430,343	3434,823	3434,983	3434,992	3433,11
	7	1998,971	1993,185	2001,735	1995,327	2015,309	2011,661	2004,819	2018,947	2014,765	2010,078	2019,249	2009,592	2013,035	2004,64	2015,367	2023,932
	8	1333,447	1338,047	1342,042	1342,825	1340,98	1338,311	1336,657	1345,354	1346,992	1350,59	1342,185	1344,259	1348,665	1336,141	1350,515	1351,343
	9	3076,526	3074,3	3092,04	3093,225	3082,186	3082,65	3080,201	3108,386	3102,983	3102,363	3100,289	3108,197	3104,625	3094,063	3098,907	3103,495
	10	1512,576	1520,529	1522,59	1531,779	1528,389	1529,76	1528,472	1527,622	1529,597	1530,715	1528,477	1534,044	1531,255	1541,085	1528,88	1529,634
4	1	2968,877	2974,673	2976,953	2982,646	2983,781	2983,182	2974,886	2986,18	2993,527	2983,145	2985,545	2979,449	2985,497	2990,744	2984,501	2989,566
	2	1685,734	1684,697	1691,253	1688,241	1688,154	1685,925	1688,085	1692,083	1692,318	1693,647	1688,929	1690,528	1689,897	1694,252	1690,332	1692,058
	3	2236,763	2233,671	2239,522	2237,048	2239,533	2243,753	2241,44	2247,71	2251,86	2244,449	2246,807	2243,106	2241,359	2241,43	2239,921	2249,022
	4	3911,946	3906,841	3913,986	3912,154	3913,167	3914,514	3910,033	3922,988	3918,909	3918,289	3915,913	3922,249	3918,58	3916,518	3921,51	3921,867
	5	6853,341	6853,016	6857,619	6859,257	6860,216	6856,958	6851,583	6870,819	6870,554	6869,962	6867,785	6865,297	6859,28	6859,328	6860,541	6864,823
	6	3622,164	3628,469	3632,114	3629,386	3631,182	3636,282	3632,784	3634,409	3639,17	3632,699	3635,723	3626,903	3632,451	3630,29	3628,696	3629,595
	7	2223,086	2220,79	2221,21	2218,413	2230,996	2229,773	2225,54	2231,388	2226,721	2232,232	2225,85	2227,68	2228,391	2224,434	2225,59	2228,059
	8	1460,392	1453,18	1462,304	1456,405	1464,13	1460,032	1465,229	1465,837	1463,322	1465,049	1463,708	1462,694	1462,984	1464,793	1467,923	1470,102
	9	3334,496	3335,009	3336,26	3342,41	3336,526	3332,321	3332,07	3346,039	3345,475	3343,608	3338,967	3337,257	3339,679	3340,703	3342,745	3343,647
	10	1731,641	1732,62	1739,704	1738,475	1734,856	1734,896	1738,816	1736,581	1737,571	1739,48	1739,4	1735,278	1740,574	1734,675	1733,197	1740,018
6	1	3054,89	3057,875	3065,102	3060,355	3065,534	3058,264	3058,435	3064,305	3062,155	3060,906	3065,791	3065,027	3063,015	3059,596	3061,147	3062,069
	2	1736,295	1740,601	1741,567	1742,609	1741,826	1738,128	1736,916	1741,491	1742,811	1743,101	1742,887	1739,93	1740,656	1740,016	1740,365	1741,52
	3	2297,228	2298,316	2299,478	2300,546	2303,911	2303,289	2302,267	2307,601	2306,669	2309,762	2304,063	2305,343	2305,631	2304,557	2306,897	2304,655
	4	3966,832	3966,346	3968,78	3968,852	3965,158	3968,234	3967,571	3971,748	3971,597	3973,789	3970,312	3971,821	3971,719	3970,195	3971,47	3973,35
	5	6948,413	6946,323	6953,707	6951,962	6949,013	6952,838	6951,862	6958,564	6952,067	6955,2	6956,26	6955,716	6947,41	6954,764	6955,349	6955,144
	6	3704,839	3703,534	3707,762	3706,617	3708,863	3710,317	3706,395	3707,58	3708,317	3706,599	3707,531	3704,282	3708,052	3706,703	3704,996	3708,614
	7	2299,587	2302,118	2304,125	2302,648	2302,855	2300,734	2303,164	2306,07	2307,361	2304,45	2305,295	2306,147	2303,055	2301,439	2302,757	2301,506
	8	1507,623	1505,338	1511,008	1509,325	1513,302	1508,243	1509,08	1513,86	1509,119	1511,701	1508,891	1510,77	1507,269	1508,652	1512,774	1511,701
	9	3418,785	3419,915	3419,67	3423,655	3421,695	3422,716	3421,299	3428,2	3423,16	3423,516	3425,031	3420,209	3425,477	3423,809	3422,04	3426,303
	10	1791,085	1795,063	1797,006	1794,699	1797,044	1795,819	1795,145	1796,587	1795,566	1798,723	1798,105	1799,672	1792,64	1796,022	1796,409	1792,647
8	1	3095,424	3098,226	3096,092	3097,604	3102,578	3099,541	3099,191	3099,212	3101,358	3101,778	3100,179	3100,502	3102,252	3099,098	3101,87	3100,961
	2	1763,605	1764,15	1765,118	1763,981	1764,757	1766,239	1764,589	1766,657	1766,214	1766,362	1767,323	1766,702	1767,332	1767,677	1766,73	1767,469

Ek Tablo 2'nin devamı

	3	2331,683	2332,329	2336,407	2333,429	2333,353	2332,681	2330,897	2334,925	2335,595	2335,206	2334,794	2335,313	2331,837	2333,505	2335,347	2335,138
	4	3991,394	3993,546	3996,526	3994,596	3995,894	3995,08	3993,947	3998,584	3996,09	3995,683	3994,939	3997,878	3995,456	3996,091	3997,743	3998,184
	5	6994,574	6992,489	6996,982	6995,766	6996,97	6996,545	6995,52	6996,596	6998,921	6995,723	6995,579	6996,429	6994,3	6996,624	6996,008	6996,598
	6	3740,619	3743,201	3744,652	3747,414	3742,679	3745,083	3742,676	3745,304	3746,505	3743,033	3742,877	3744,669	3741,516	3742,274	3745,246	3744,463
	7	2338,008	2339,88	2341,908	2341,752	2340,785	2343,072	2344,421	2343,893	2344,684	2344,975	2344,928	2343,454	2339,125	2339,513	2343,181	2342,491
	8	1532,206	1534,454	1535,469	1534,594	1536,051	1536,161	1533,073	1534,429	1534,321	1534,774	1534,544	1535,912	1535,287	1535,801	1535,95	1535,511
	9	3460,832	3461,665	3461,833	3464,059	3465,007	3463,435	3460,846	3464,962	3464,063	3464,794	3464,007	3464,592	3463,611	3459,917	3463,195	3462,235
	10	1821,58	1823,373	1825,424	1823,769	1823,732	1823,699	1823,89	1826,243	1824,103	1824,848	1822,675	1822,179	1823,944	1824,598	1821,639	1825,766
10	1	3121,566	3121,436	3122,419	3123,941	3122,662	3123,408	3122,736	3122,229	3125,366	3124,473	3122,204	3123,704	3125,035	3123,791	3122,537	3124,241
	2	1779,86	1778,508	1780,32	1781,454	1780,51	1780,512	1781,793	1781,902	1781,122	1782,374	1781,871	1780,933	1781,002	1780,946	1780,107	1781,327
	3	2348,292	2350,154	2350,028	2348,608	2350,075	2349,618	2349,901	2352,94	2351,65	2352,243	2351,126	2351,07	2352,178	2351,473	2351,447	2351,905
	4	4011,765	4010,708	4012,009	4012,243	4012,024	4012,82	4011,999	4013,106	4013,321	4013,07	4013,452	4013,395	4013,246	4011,017	4013,645	4012,578
	5	7018,332	7016,6	7018,802	7020,395	7019,052	7018,817	7019,594	7019,27	7018,496	7018,313	7017,208	7019,206	7017,496	7019,534	7018,535	7019,683
	6	3765,221	3765,084	3766,547	3764,597	3764,329	3765,063	3766,101	3764,879	3766,703	3767,271	3766,753	3766,111	3763,796	3764,821	3767,254	3767,566
	7	2362,372	2364,721	2367,784	2365,264	2367,074	2365,771	2363,436	2366,816	2364,538	2366,595	2365,153	2365,298	2364,94	2364,768	2366,19	2365,625
	8	1547,35	1548,857	1550,523	1549,75	1550,339	1548,436	1550,902	1548,917	1550,333	1551,165	1549,411	1550,627	1548,317	1550,911	1550,535	1550,003
	9	3484,584	3486,2	3487,555	3486,881	3486,499	3486,478	3488,178	3486,453	3485,418	3487,519	3487,666	3485,411	3485,499	3486,559	3486,85	3486,332
	10	1840,401	1841,179	1839,402	1839,981	1840,279	1841,144	1840,132	1840,866	1842,475	1840,578	1839,741	1840,352	1840,648	1840,58	1839,715	1838,935
12	1	3134,44	3136,6	3136,688	3138,253	3139,368	3137,47	3137,295	3137,719	3137,197	3138,016	3137,149	3136,706	3136,78	3137,356	3137,76	3138,711
	2	1791,053	1790,06	1792,763	1791,236	1792,344	1790,594	1791,359	1791,675	1791,034	1790,569	1792,46	1792,275	1792,191	1790,135	1790,75	1791,757
	3	2359,776	2360,097	2361,101	2359,697	2361,586	2361,25	2362,324	2362,188	2362,023	2363,447	2360,705	2362,297	2360,749	2362,513	2362,617	2362,435
	4	4021,808	4020,994	4022,981	4022,752	4023,066	4021,606	4022,534	4024,395	4022,699	4023,96	4021,734	4021,895	4023,016	4022,624	4021,904	4023,955
	5	7030,88	7030,263	7032,821	7033,733	7033,572	7034,036	7033,335	7034,657	7033,916	7034,09	7035,272	7035,66	7034,446	7034,704	7034,734	7035,379
	6	3778,642	3777,926	3780,491	3780,75	3779,242	3780,082	3779,822	3779,739	3778,284	3777,89	3779,966	3780,146	3778,824	3780,96	3778,195	3779,976
	7	2379,771	2377,931	2379,529	2379,473	2378,306	2380,184	2380,402	2379,799	2379,072	2379,993	2378,707	2378,749	2381,309	2380,605	2380,009	2378,113
	8	1560,064	1560,418	1560,195	1560,076	1560,009	1559,923	1558,566	1560,584	1560,862	1560,471	1559,653	1560,866	1560,978	1560,251	1560,321	1559,517
	9	3499,543	3500,39	3502,058	3499,72	3501,449	3501,565	3500,338	3502,946	3500,596	3500,458	3499,782	3500,154	3500,313	3500,551	3500,373	3501,486
	10	1850,506	1851,965	1851,88	1851,197	1851,601	1850,497	1851,715	1851,901	1850,073	1851,44	1852,009	1852,028	1851,357	1850,521	1851,529	1850,593

Ek Tablo 3. Kapur entropisi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=500 \times m$)

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	18,1368	18,1495	18,1504	18,1494	18,1632	18,1736	18,1471	18,2009	18,1946	18,2044	18,1758	18,1809	18,2032	18,1845	18,1916	18,2008
	2	18,0276	18,0032	18,0657	18,0593	18,0543	18,0177	18,047	18,0856	18,1052	18,0902	18,078	18,0693	18,0614	18,0614	18,0838	18,0919
	3	17,8067	17,8181	17,8302	17,8242	17,8262	17,8136	17,8316	17,8491	17,8478	17,8388	17,8436	17,8549	17,8541	17,8398	17,8438	17,8435
	4	17,3608	17,345	17,3875	17,3788	17,3903	17,3786	17,3965	17,4064	17,4134	17,4035	17,3928	17,4041	17,3985	17,3698	17,4153	17,4212
	5	17,3849	17,3863	17,406	17,4029	17,4068	17,4298	17,3984	17,4043	17,4041	17,4353	17,4279	17,4156	17,4117	17,4338	17,4406	17,4414
	6	17,8873	17,8691	17,8656	17,8723	17,8879	17,8913	17,8743	17,9317	17,928	17,9144	17,9088	17,9001	17,9154	17,9083	17,9171	17,9069
	7	18,1286	18,1174	18,1355	18,1574	18,15	18,1378	18,1427	18,1656	18,1567	18,1552	18,1458	18,162	18,1512	18,1626	18,1518	18,1656
	8	17,5944	17,6346	17,635	17,6231	17,626	17,6348	17,6321	17,6589	17,6475	17,6441	17,64	17,6536	17,646	17,6345	17,6525	17,6411
	9	18,3431	18,3341	18,3436	18,3457	18,339	18,3386	18,3415	18,3703	18,3682	18,3587	18,3698	18,367	18,3621	18,363	18,3683	18,3682
	10	18,0356	18,0645	18,0733	18,055	18,0808	18,0447	18,0507	18,1101	18,1507	18,0802	18,0885	18,0821	18,1104	18,0959	18,0825	18,0971
4	1	26,4539	26,4284	26,4731	26,4156	26,4775	26,4549	26,4864	26,5186	26,5047	26,5007	26,5128	26,5246	26,4933	26,4718	26,5715	26,5016
	2	26,3788	26,3047	26,3303	26,4531	26,4889	26,4297	26,4394	26,3991	26,4708	26,4446	26,5001	26,4214	26,4541	26,4777	26,4939	26,4452
	3	26,4427	26,4858	26,5249	26,4666	26,4531	26,4824	26,4223	26,5849	26,5481	26,5693	26,5682	26,5274	26,4975	26,5018	26,4828	26,5274
	4	25,6216	25,6072	25,6957	25,6062	25,7166	25,6618	25,6951	25,6017	25,6222	25,6223	25,6714	25,6784	25,6324	25,6215	25,652	25,6894
	5	25,6124	25,5358	25,6154	25,5895	25,5836	25,5274	25,5314	25,6095	25,6523	25,6135	25,5681	25,578	25,5379	25,5764	25,5522	25,5412
	6	26,1631	26,2231	26,3128	26,2759	26,2423	26,2248	26,2327	26,4739	26,3593	26,3372	26,3865	26,3561	26,2638	26,2528	26,3736	26,3258
	7	26,3218	26,3635	26,4778	26,3858	26,3946	26,4247	26,4358	26,5133	26,5152	26,4276	26,4399	26,4671	26,5647	26,4607	26,4813	26,5471
	8	25,9399	25,9303	26,0078	26,0783	26,063	26	26,0022	26,0315	26,0062	25,993	26,0578	26,0148	26,0233	26,0069	26,0273	26,0043
	9	26,7513	26,879	26,8558	26,8437	26,8399	26,8632	26,8239	26,8969	26,9082	26,9186	26,8429	26,8481	26,8754	26,8951	26,9046	26,875
	10	26,2302	26,2562	26,2434	26,2701	26,2801	26,3174	26,3167	26,3262	26,3428	26,301	26,2635	26,3042	26,3619	26,262	26,4016	26,324
6	1	33,4881	33,4789	33,4362	33,5008	33,455	33,5565	33,5867	33,6363	33,5198	33,608	33,5764	33,6229	33,5652	33,4892	33,5142	33,5267
	2	33,3792	33,3621	33,4635	33,564	33,4128	33,4581	33,4538	33,6097	33,4946	33,4979	33,5459	33,4593	33,5911	33,5293	33,6642	33,5527
	3	33,6629	33,5176	33,6249	33,7471	33,7072	33,5948	33,6511	33,7211	33,6852	33,6837	33,5923	33,623	33,6931	33,6465	33,7448	33,6681
	4	32,3543	32,4357	32,3928	32,4529	32,4432	32,5597	32,4003	32,3804	32,4711	32,5401	32,3967	32,515	32,5093	32,4202	32,4526	32,4715
	5	32,3666	32,2859	32,5567	32,5066	32,3881	32,1976	32,4537	32,3448	32,4425	32,3195	32,4851	32,3525	32,4157	32,4185	32,5036	32,3567
	6	33,3052	33,2489	33,4477	33,3065	33,409	33,4168	33,472	33,4858	33,4425	33,5066	33,425	33,5106	33,4404	33,2458	33,3576	33,3715
	7	33,3317	33,3949	33,4652	33,3841	33,435	33,4475	33,4994	33,4899	33,4827	33,4509	33,5129	33,4304	33,4929	33,4655	33,4772	33,5274
	8	32,8515	32,8558	33,074	32,9753	33,1121	32,9505	33,0525	33,0334	32,9492	32,9474	33,0794	32,9334	32,9713	32,951	32,9555	32,9727
	9	33,741	33,9225	33,9594	33,917	33,8178	33,9487	33,9579	34,0233	33,8619	33,9986	33,9097	33,9555	33,9271	33,9303	33,9552	33,8695
	10	33,2457	33,2254	33,3001	33,1889	33,3985	33,2375	33,3563	33,3365	33,3026	33,3389	33,2596	33,2962	33,3404	33,2061	33,3431	33,3367
8	1	39,6542	39,6046	39,7289	39,6203	39,7214	39,8244	39,7647	39,7776	39,8255	39,7105	39,69	39,7053	39,4951	39,508	39,6522	39,8859
	2	39,485	39,6532	39,6704	39,5308	39,7228	39,583	39,6784	39,5275	39,6197	39,4752	39,437	39,6264	39,6404	39,798	39,7203	39,6696

Ek Tablo 3'ün devamı

10	3	39,7851	39,6724	39,9963	39,9955	39,9304	39,9017	40,0142	39,8485	40,0934	39,8218	39,945	39,9171	39,8935	39,8617	39,9746	39,9929
	4	38,1632	38,2725	38,4891	38,5041	38,5406	38,2242	38,4625	38,4729	38,3803	38,4304	38,394	38,4037	38,3038	38,4777	38,433	38,6501
	5	38,1944	38,1337	38,2023	38,3373	38,1977	38,3534	38,4304	38,2755	38,3406	38,3951	38,3723	38,3594	38,3531	38,3149	38,3107	38,4203
	6	39,3847	39,4799	39,6881	39,6054	39,4553	39,5818	39,611	39,6223	39,4673	39,4256	39,6146	39,7396	39,6074	39,4367	39,469	39,6697
	7	39,2328	39,51	39,6203	39,6535	39,5779	39,5167	39,5965	39,7636	39,6175	39,8066	39,6526	39,6249	39,6013	39,6118	39,8343	39,6979
	8	38,8108	38,9866	39,0569	39,1751	39,0468	39,1035	39,0333	39,113	38,9369	39,1589	38,9883	39,0233	39,1143	39,0571	39,1615	39,174
	9	39,9452	40,0001	40,2522	40,1259	40,0237	40,1405	40,1069	40,0891	40,0831	40,0731	40,1034	40,1618	40,0762	39,946	40,0216	40,1562
	10	39,2797	39,3825	39,5154	39,4897	39,3565	39,3714	39,3999	39,5358	39,3702	39,4511	39,3866	39,5534	39,6257	39,4653	39,6519	39,4061
	1	44,8822	44,9997	45,1163	45,1197	45,1888	44,8987	45,1579	45,2963	45,0898	45,3264	45,0398	44,973	45,2482	45,1778	45,1222	45,1331
	2	44,8819	45,0948	45,129	45,179	45,2404	45,0329	45,1829	45,2981	45,2153	45,1134	45,1707	45,1432	45,0196	45,208	45,187	45,2354
12	3	45,3413	45,18	45,3556	45,2069	45,2663	45,395	45,268	45,4197	45,3401	45,2721	45,2157	45,4078	45,3667	45,3441	45,5054	45,3096
	4	43,6398	43,4466	43,6701	43,6728	43,627	43,6456	43,7502	43,6682	43,8048	43,8289	43,6656	43,7246	43,6448	43,7593	43,7299	43,6969
	5	43,4534	43,5257	43,5974	43,4677	43,6007	43,687	43,6364	43,5042	43,5713	43,7285	43,6775	43,456	43,687	43,666	43,4754	43,5855
	6	45,0327	44,7496	45,1609	44,9878	44,9379	45,2286	45,1243	45,1544	45,1039	45,0628	44,9768	45,2049	44,8993	44,9117	45,0701	45,093
	7	45,0507	45,0746	45,153	45,1249	45,1072	45,2943	44,9489	45,0178	45,4016	45,2151	45,2035	45,1389	44,9937	45,1838	45,0679	45,0423
	8	44,3647	44,1358	44,4024	44,5367	44,4388	44,51	44,4058	44,3472	44,3247	44,4524	44,2478	44,3878	44,4963	44,7413	44,3989	44,3034
	9	45,3902	45,5319	45,7924	45,602	45,7649	45,5799	45,5285	45,5358	45,5386	45,5355	45,526	45,5584	45,6132	45,6222	45,6588	45,4983
	10	44,6622	44,616	44,81	44,9342	44,6821	45,0056	45,054	44,985	45,0997	44,8781	45,0954	45,0189	44,9863	45,0284	44,9154	44,9266
	1	50,109	49,9629	50,0388	50,125	50,0391	50,1448	50,0414	49,9765	50,0937	50,0517	50,1259	49,9864	50,0199	50,197	49,889	50,0596
	2	49,9664	49,7223	49,9106	50,0551	49,8345	50,1219	49,934	50,2139	50,1742	50,1666	50,0424	50,3589	49,9034	50,1255	50,04	50,1106
12	3	49,9935	50,118	50,417	50,166	50,2849	50,1546	50,279	50,225	50,2676	50,3137	50,1273	50,2022	50,0886	50,3255	50,2872	50,3428
	4	48,5401	48,1495	48,6916	48,5116	48,5148	48,5933	48,4214	48,5913	48,7052	48,6342	48,5408	48,5321	48,5956	48,5771	48,4713	48,6433
	5	48,3381	48,4181	48,5006	48,4079	48,4935	48,2765	48,4177	48,3548	48,3507	48,3383	48,5297	48,315	48,3769	48,2988	48,2412	48,32
	6	49,6864	49,9849	49,7779	50,0558	49,7857	49,9004	49,856	50,1134	49,9286	49,9738	50,0922	50,1288	49,9031	49,8098	49,9603	49,8359
	7	49,9754	49,716	50,0195	49,939	49,8953	49,8407	49,9006	50,0693	49,8907	49,89	49,9685	49,7241	49,9627	49,9248	49,7795	50,1329
	8	49,2573	48,9175	49,1518	49,3701	49,2196	49,0886	49,1584	49,2261	49,2652	49,1936	49,2525	49,218	49,1627	49,0611	49,4244	49,0695
	9	50,2301	50,2229	50,3961	50,4003	50,2643	50,4754	50,5842	50,5423	50,54	50,5797	50,3907	50,6312	50,528	50,6036	50,5787	50,7503
	10	49,6697	49,8004	50,0617	49,7402	49,8911	49,9707	49,9199	49,7979	49,6791	49,7734	49,8626	49,8722	49,7396	49,8031	49,6657	49,705

Ek Tablo 4. Kapur entropisi ile elde edilen amaç fonksiyonu değerleri ($maxFEs=1000 \times m$)

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	18,14767	18,13094	18,1706	18,1763	18,15902	18,15733	18,15842	18,19908	18,18993	18,21243	18,19995	18,1898	18,21218	18,19041	18,21445	18,18947
	2	18,03548	18,04131	18,06446	18,06117	18,0455	18,05398	18,03799	18,10483	18,07465	18,09165	18,05807	18,07813	18,07329	18,05629	18,10201	18,07103
	3	17,80331	17,80336	17,81195	17,82112	17,82046	17,83214	17,82238	17,85262	17,86083	17,8524	17,85095	17,84297	17,85441	17,85617	17,8447	17,85286
	4	17,35137	17,3603	17,36821	17,39731	17,37465	17,37207	17,38428	17,41553	17,40805	17,41799	17,40426	17,41843	17,40648	17,39298	17,41902	17,40711
	5	17,38128	17,37724	17,41204	17,41878	17,40728	17,41961	17,44221	17,42032	17,4561	17,43498	17,43644	17,43847	17,42513	17,44203	17,44836	17,4398
	6	17,85486	17,88621	17,87982	17,85654	17,88892	17,88606	17,87789	17,93224	17,92762	17,92564	17,9212	17,91601	17,92705	17,90224	17,93199	17,9277
	7	18,12772	18,1302	18,14183	18,13664	18,1557	18,12931	18,15508	18,15076	18,15666	18,17117	18,14625	18,15145	18,16522	18,1595	18,16667	18,1595
	8	17,63711	17,61779	17,63876	17,63061	17,62358	17,63015	17,62539	17,64223	17,65881	17,66365	17,63959	17,65032	17,63577	17,64002	17,6584	17,66009
	9	18,31646	18,33367	18,3554	18,34978	18,3481	18,3326	18,36228	18,3818	18,37625	18,37861	18,35392	18,35187	18,36521	18,36164	18,38287	18,36859
	10	17,97393	18,07125	18,08454	18,09579	18,06028	18,06278	18,06706	18,14419	18,11791	18,13396	18,0909	18,10422	18,09185	18,11055	18,13765	18,11907
4	1	26,45411	26,49577	26,46763	26,51827	26,52109	26,37835	26,44376	26,54081	26,46818	26,50042	26,47643	26,48671	26,49013	26,47642	26,49001	26,48164
	2	26,41446	26,38574	26,44305	26,47022	26,45463	26,38107	26,43198	26,42908	26,44045	26,44121	26,5088	26,46203	26,53786	26,43117	26,50607	26,4463
	3	26,46942	26,51004	26,52149	26,50308	26,49363	26,54053	26,53705	26,60181	26,56951	26,56363	26,5526	26,56726	26,5393	26,50209	26,64571	26,55301
	4	25,56042	25,57624	25,68935	25,65565	25,65457	25,59623	25,60746	25,69804	25,611	25,65392	25,71042	25,62291	25,59629	25,57642	25,679	25,68349
	5	25,55369	25,52038	25,61886	25,5496	25,58135	25,58361	25,62801	25,65459	25,61591	25,65066	25,59056	25,63827	25,54597	25,57407	25,59334	25,66629
	6	26,21546	26,33326	26,20094	26,33933	26,21618	26,21344	26,22824	26,45373	26,37172	26,37147	26,36239	26,33055	26,33268	26,31199	26,44998	26,396
	7	26,36208	26,34238	26,38897	26,48381	26,47322	26,46747	26,49504	26,57432	26,50681	26,50331	26,4587	26,45247	26,47756	26,45941	26,57866	26,57071
	8	25,93116	25,93602	26,00725	25,97441	25,97139	25,98878	25,9372	26,07068	26,00795	26,03467	26,04199	25,9663	26,02882	26,01842	26,01283	26,11938
	9	26,77231	26,69385	26,80852	26,8244	26,82993	26,79953	26,84699	26,93628	26,85897	26,85395	26,90196	26,85769	26,81279	26,86008	26,88192	26,81662
	10	26,25558	26,27341	26,25688	26,34134	26,34536	26,37695	26,35838	26,35346	26,33527	26,36767	26,35638	26,2694	26,27992	26,31037	26,38804	26,37315
6	1	33,4515	33,25011	33,55813	33,51956	33,50482	33,55953	33,59693	33,57825	33,54553	33,54547	33,53485	33,55454	33,60941	33,5472	33,52901	33,60797
	2	33,40765	33,45009	33,42256	33,52358	33,5153	33,46041	33,46082	33,44747	33,51116	33,46381	33,54713	33,43534	33,49627	33,37366	33,54357	33,51226
	3	33,58536	33,58532	33,65183	33,65621	33,72072	33,7373	33,66937	33,71241	33,66462	33,74637	33,66762	33,72286	33,69372	33,77121	33,75552	33,70939
	4	32,49754	32,34782	32,46224	32,38508	32,34306	32,58224	32,40728	32,53399	32,44133	32,43247	32,46814	32,46897	32,54414	32,40828	32,49744	32,53452
	5	32,36725	32,26664	32,44736	32,34947	32,387	32,32351	32,45205	32,47504	32,44833	32,3924	32,35943	32,43733	32,33557	32,43614	32,29951	32,40067
	6	33,2055	33,25917	33,37502	33,53466	33,37561	33,29754	33,3959	33,46313	33,45195	33,34519	33,38993	33,47251	33,39113	33,3158	33,43185	33,34999
	7	33,45087	33,39688	33,44662	33,47276	33,48429	33,40911	33,42005	33,53621	33,52511	33,47694	33,40846	33,40971	33,54687	33,47438	33,47561	33,47385
	8	32,9779	32,92014	32,98793	33,05843	32,96037	32,93879	33,07143	33,11083	33,02706	32,97006	33,01841	33,05868	33,0533	32,99018	32,9083	33,01988
	9	33,81094	33,74961	33,783	33,88444	33,95812	33,96249	33,91559	33,96463	33,95603	33,96877	33,92999	33,9384	34,05527	33,93774	33,94578	33,97326
	10	33,28266	33,21682	33,30882	33,24799	33,43251	33,37281	33,20692	33,34553	33,36816	33,32621	33,2521	33,31283	33,42095	33,36549	33,42146	33,36
8	1	39,61619	39,73444	39,80483	39,66656	39,66644	39,5157	39,63022	39,72881	39,80459	39,81017	39,61505	39,55615	39,59445	39,50606	39,69517	39,81722
	2	39,55134	39,43212	39,60872	39,69203	39,66785	39,70041	39,63695	39,65217	39,71897	39,62055	39,6188	39,67131	39,61876	39,59041	39,65323	39,64281

Ek Tablo 4'ün devamı

	3	39,86984	39,8125	39,67683	39,97458	39,87572	39,86595	39,77221	39,94652	39,68267	39,94661	39,96453	39,91404	39,72687	39,91332	39,88874	39,90031
	4	38,17033	38,132	38,44714	38,31689	38,34957	38,55186	38,40441	38,33903	38,3483	38,43328	38,4049	38,50501	38,46182	38,35493	38,43056	38,371
	5	38,23064	38,27734	38,41144	38,30036	38,41316	38,36922	38,18967	38,32183	38,35115	38,36294	38,30981	38,10742	38,37185	38,13765	38,36784	38,29102
	6	39,42494	39,40974	39,35673	39,59573	39,51797	39,59392	39,6625	39,6626	39,496	39,62821	39,57474	39,4446	39,63336	39,49125	39,55237	39,59789
	7	39,50614	39,50019	39,58542	39,51079	39,71337	39,53761	39,62085	39,66342	39,59722	39,5828	39,57987	39,60705	39,72523	39,46582	39,67508	39,69874
	8	38,93266	39,00621	39,09022	39,1185	39,08479	39,10099	38,95904	39,08682	39,17427	38,9643	39,09046	39,0037	39,15757	38,98593	39,07067	39,01538
	9	39,98336	40,01724	40,13166	40,03665	39,93635	40,07195	39,9658	40,06786	40,13363	40,16175	40,07089	40,12013	40,10346	40,01587	39,96663	40,1872
	10	39,39958	39,36145	39,50872	39,37392	39,52514	39,56563	39,51435	39,45128	39,48531	39,35781	39,47265	39,45034	39,40272	39,38493	39,31822	39,46983
10	1	44,92595	44,95815	45,21949	45,1099	45,09598	45,12465	45,0463	45,14486	45,12236	45,02631	45,09462	45,24978	45,19072	45,09997	45,07104	45,11422
	2	45,10123	44,90234	44,93527	45,12066	45,03765	45,26456	45,12176	44,92208	45,27619	44,99618	45,13704	44,95219	45,05646	45,11301	45,12826	44,94391
	3	45,33742	45,26626	45,24897	45,30273	45,37859	45,31484	45,04918	45,278	45,37698	45,40136	45,30858	45,39703	45,35297	45,58491	45,22899	45,33917
	4	43,50313	43,53852	43,763	43,70024	43,58653	43,73774	43,73979	43,7704	43,79688	43,76505	43,79787	43,90749	43,72222	43,97637	43,85429	43,73717
	5	43,63578	43,43302	43,6041	43,53632	43,59172	43,63244	43,64133	43,54618	43,64329	43,52081	43,68556	43,77432	43,69026	43,61376	43,61396	43,77545
	6	44,79116	44,69378	44,95352	45,14394	45,05991	45,10844	44,97361	45,12902	45,04685	45,12224	45,06401	45,15218	45,0628	45,04891	44,9441	44,88314
	7	44,72092	44,98178	45,13074	45,26071	44,96883	44,95387	45,18099	45,07318	45,06851	45,10503	44,99298	44,9644	45,01149	44,92416	45,09605	45,09465
	8	44,23667	44,24473	44,61695	44,54812	44,50249	44,29764	44,50204	44,51436	44,1498	44,54256	44,36598	44,61207	44,38549	44,444	44,30322	44,46693
	9	45,3229	45,57873	45,56259	45,61144	45,45204	45,53985	45,45206	45,48565	45,75407	45,56553	45,62937	45,6216	45,44957	45,49804	45,60375	45,50334
	10	44,92842	44,85422	44,84946	45,05544	44,96633	45,03428	44,84723	44,9047	44,7788	45,07599	44,86051	44,89302	44,86029	44,83001	44,98793	44,97868
12	1	49,78205	49,8361	50,04419	50,21734	49,99091	49,82745	50,01663	50,10595	49,79905	49,89117	49,88565	50,06645	50,23328	50,13346	49,95705	50,0251
	2	49,83734	49,95527	49,98204	49,94922	50,08179	50,00675	50,01161	50,21002	50,16448	50,03838	50,02838	50,14471	49,76841	50,07433	49,97784	49,89936
	3	50,06286	49,94907	50,37016	50,19918	50,39154	50,15233	50,24491	50,15173	50,36946	50,46397	50,20066	50,4642	50,24402	50,28325	50,2416	50,18644
	4	48,46481	48,4162	48,38105	48,59382	48,56587	48,41846	48,29729	48,46708	48,541	48,566	48,43065	48,64118	48,53838	48,45138	48,42021	48,5094
	5	48,29496	48,34059	48,51369	48,48596	48,43813	48,28108	48,47765	48,18402	48,38687	48,33268	48,24718	48,55036	48,48688	48,42496	48,28621	48,4933
	6	49,67198	49,90532	49,8098	49,8688	49,98022	50,14472	49,9891	49,90174	49,97372	49,9395	49,96144	49,8182	50,10642	50,10527	49,81942	50,13004
	7	49,70595	49,89153	49,69365	50,0052	49,87504	49,75096	49,91409	50,03998	49,90816	49,9625	49,86982	49,85514	49,94627	50,00567	50,03323	49,95783
	8	49,03439	48,85467	49,17105	49,20734	49,4654	49,03844	49,08351	49,40737	49,23467	49,35353	49,52265	49,18356	49,19272	49,36735	49,2972	49,24936
	9	50,1249	50,47053	50,51145	50,33997	50,38923	50,70062	50,75394	50,66751	50,392	50,63045	50,47724	50,54064	50,4711	50,44517	50,36818	50,20471
	10	49,67426	49,66839	50,04147	49,81449	49,98884	50,04108	49,90323	49,92433	49,9133	49,75571	49,98039	49,77503	49,8586	49,76656	49,83744	49,85563

Otsu Yöntemi:

- EK Tablo 5 ($maxFEs = 500 \times m$): WChOA ve varyantları, 60 deneyin 49'unda en yüksek PSNR değerlerini elde etmiştir.
- EK Tablo 6 ($maxFEs = 1000 \times m$): En yüksek PSNR değerlerine sahip deney sayısı 48'dir.

Kapur Entropisi:

- EK Tablo 7 ($maxFEs = 500 \times m$): Önerilen yöntem, 60 deneyin 45'inde üstün PSNR değerleri sağlamıştır.
- EK Tablo 8 ($maxFEs = 1000 \times m$): Yöntem, 44 deneyde rakiplerini geride bırakmıştır.

Ek Tablo 5. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların PSNR sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	15,2146	15,2125	15,3533	15,2699	15,0792	15,2377	15,2928	15,4980	15,4506	15,5149	15,4959	15,4494	15,3061	15,3802	15,4706	15,5359
	2	15,6043	15,6597	15,8207	15,7025	15,7936	15,6172	15,8370	16,3469	16,1992	16,2207	16,1118	16,2222	16,1883	15,9412	16,1080	16,2897
	3	18,8102	18,8031	18,8875	18,9604	18,9156	19,0257	18,9610	19,0456	19,0639	19,0018	19,0878	19,0100	19,0192	19,0069	18,9576	19,0278
	4	16,1244	16,2434	16,1649	16,2948	16,0843	16,1049	16,2105	16,4578	16,4866	16,4694	16,6136	16,4128	16,5526	16,3746	16,4435	16,5902
	5	14,1860	14,2014	14,2603	14,3851	14,0255	14,2756	14,1340	14,1586	14,1262	14,2384	14,3169	14,0796	14,0552	14,0286	14,1487	14,0754
	6	12,1365	12,1332	12,1100	12,2167	12,0911	12,1150	12,1692	12,1924	12,2443	12,2341	12,1284	12,3256	12,1702	12,2797	12,3463	12,1539
	7	13,1015	13,2390	13,0939	13,2284	13,0114	13,0758	13,1085	13,4251	13,3124	13,5060	13,2906	13,1822	13,4127	13,1526	13,4332	13,2526
	8	14,3331	14,3223	14,4863	14,4815	14,1799	14,2331	14,4457	14,6842	14,8509	14,7294	14,6080	14,5735	14,5480	14,7121	14,7860	14,5501
	9	15,2301	15,2053	15,3255	15,3365	15,3159	15,2224	15,3579	15,4079	15,4300	15,4729	15,3472	15,3976	15,5179	15,4227	15,4085	15,3953
	10	12,7744	13,0093	13,2084	13,1371	12,9625	12,8065	13,1358	13,1605	13,1280	13,2627	13,0833	13,0933	13,0072	13,1088	13,1878	12,8761
4	1	18,3039	18,6849	18,5307	18,5153	18,6793	18,5148	18,5386	18,8487	19,0406	19,1861	18,7731	18,8682	18,7978	19,0260	18,9276	18,9116
	2	18,6843	18,7350	18,5603	18,4840	18,4378	18,4716	18,5138	19,1571	19,3219	19,1163	18,7328	18,8504	18,9321	18,7826	19,1352	18,9928
	3	21,5301	21,4668	21,5911	21,3329	21,5772	21,5495	21,5968	21,8881	21,9191	21,8904	21,7412	21,8183	21,7250	21,7521	21,7947	21,8163
	4	19,1676	19,1146	19,1629	19,3522	18,9982	19,1714	19,2906	19,2751	19,3161	19,3300	19,4287	19,3458	19,3672	19,1438	19,4015	19,4964
	5	18,0660	18,1691	18,0940	18,1944	18,1033	18,3448	18,1469	17,9758	17,9804	18,0779	18,1212	18,2008	18,0146	18,0803	18,1743	18,1821
	6	15,9426	16,0826	16,2417	15,9920	15,9500	15,8311	16,0212	16,4161	16,0379	15,7875	15,5581	15,6494	16,2059	15,8516	16,0800	15,7919
	7	16,9206	16,8183	16,8642	17,0368	17,1378	16,9439	17,0050	17,1643	16,9525	16,9028	16,8619	17,0643	16,9231	17,2109	17,1877	17,2278
	8	16,8203	17,4544	17,6235	17,3128	17,1373	17,1010	17,0318	17,9507	17,7418	18,0884	17,6820	17,3225	17,8764	17,0735	17,9318	17,5921
	9	18,4156	18,4403	18,5883	18,5330	18,5331	18,3966	18,4884	18,5790	18,5626	18,8239	18,6958	18,5655	18,4646	18,4713	18,7400	18,6497

Ek Tablo 5'in devamı

	10	17,6218	17,4819	17,8337	17,6458	17,6454	17,6372	17,6117	17,8648	18,1866	17,7960	17,7647	17,5956	17,4676	17,5539	17,5275	18,0382
6	1	20,7305	20,9450	20,8808	20,7363	20,7931	20,7891	20,5106	21,2269	21,0616	21,0674	20,9985	20,9355	21,0832	20,8706	21,1382	21,1240
	2	20,4102	20,7995	20,3943	20,8746	20,8528	20,8562	20,7238	21,2298	21,4540	21,3385	21,4070	21,3456	21,0379	20,9512	21,2483	21,1613
	3	23,4244	23,3188	23,3956	23,4001	23,4973	23,4214	23,5484	23,6499	23,6831	23,8089	23,6914	23,7043	23,6315	23,8214	23,8935	23,7359
	4	21,3519	21,2323	21,2682	21,3421	21,1179	21,1234	20,9848	21,5555	21,3309	21,3193	21,3160	21,4378	21,1923	21,2108	21,4696	21,1957
	5	20,5321	20,5300	20,5220	20,5584	20,5150	20,4756	20,5883	20,4770	20,5323	20,4417	20,4648	20,3898	20,5550	20,5189	20,8968	20,4460
	6	18,6875	18,8577	18,7760	18,6965	18,4485	18,9258	19,1620	19,0737	18,3911	18,7431	18,8363	18,4153	18,5397	18,9397	18,7948	19,1476
	7	19,7397	19,2105	19,6276	19,2849	19,3871	19,7330	19,4103	19,7529	19,5373	19,6950	19,5395	19,4951	19,8048	19,4682	19,4309	19,5671
	8	19,0391	19,7151	20,2123	19,8851	19,9489	20,0443	19,8661	20,5602	19,9864	20,1661	19,9577	20,2626	20,0464	20,1620	19,7503	20,1329
	9	20,6010	20,7230	20,7238	20,7706	20,8271	20,7393	20,6593	20,8482	20,9717	20,8315	20,6980	20,8111	20,8716	20,6823	20,9068	20,9348
	10	20,3843	20,2677	20,3134	20,3029	20,2337	20,1639	20,6781	20,2529	20,6903	20,8286	20,4508	20,3150	20,3586	20,3468	20,2211	20,1446
8	1	22,2694	22,1716	22,6149	22,4774	22,5761	22,2495	22,5102	22,7681	22,8614	22,8629	22,6045	22,5461	22,7260	22,6642	22,7053	22,6249
	2	22,2302	22,3789	22,3931	22,1547	22,5426	22,5073	22,3138	22,7593	23,1913	23,1077	22,6939	22,7296	22,6352	22,9002	23,2288	22,7773
	3	24,7040	24,8731	24,9951	24,9348	24,9623	24,9875	24,9194	25,3180	25,0476	25,1836	25,1506	25,1345	25,1540	25,2076	25,0745	25,2622
	4	22,5512	22,7445	22,7645	22,5608	22,7029	22,7535	22,8354	23,0308	22,8374	23,0693	23,1422	22,8205	22,9884	22,7335	22,9433	23,0241
	5	22,2226	22,3349	22,5030	22,2149	22,4140	22,2242	22,2682	22,2977	22,5301	22,3834	22,4800	22,4472	22,2105	22,3839	22,5833	22,4983
	6	21,1074	20,7872	20,7866	20,6879	21,1066	20,6734	20,8436	21,0457	20,9208	20,7561	20,9429	20,7716	21,1373	21,0280	21,0055	20,4909
	7	21,5956	21,4946	21,5185	21,2892	21,2531	21,5153	21,7441	21,6791	21,6155	21,5565	21,4013	21,1829	21,5753	21,4534	21,5151	21,3413
	8	21,6368	21,3419	21,5909	21,5940	21,3464	21,7044	21,4673	21,9513	22,5966	21,9980	21,6878	22,3011	21,6629	21,9924	21,7946	22,0422
	9	22,2520	22,2274	22,4150	22,4832	22,2180	22,3328	22,3767	22,2791	22,4372	22,4257	22,4839	22,3707	22,4291	22,2823	22,4803	22,5083
	10	22,1471	22,0032	22,4460	21,9844	22,2551	22,3295	22,3411	22,1058	22,4044	22,1102	22,1902	22,2323	22,2676	22,2372	22,3374	22,2399
10	1	23,5903	23,6592	23,8801	23,7894	23,7755	23,7380	23,6847	24,1740	23,9940	24,1367	23,7659	24,0584	24,0012	23,8223	24,1462	24,2188
	2	24,4424	23,5395	24,0065	24,1450	24,1059	23,9654	24,1878	24,4041	24,2377	24,6166	24,0639	24,2082	23,8728	24,0853	24,3633	24,1039
	3	26,0936	25,8886	26,1069	26,0801	26,1618	26,2494	26,0670	26,4240	26,3977	26,5015	26,2844	26,4774	26,4064	26,3685	26,4358	26,4002
	4	23,9763	24,2202	24,2804	24,1661	24,1329	24,0997	24,3400	24,3053	24,2364	24,2063	24,0903	24,2552	24,1305	24,0685	24,3248	24,2512
	5	23,8394	23,6684	23,6624	23,8601	23,8062	23,6684	23,7192	23,8039	23,8269	23,7040	23,7044	23,8909	23,9690	23,8103	23,9194	23,7893
	6	22,5736	22,8214	22,6420	22,5104	22,7482	22,1830	22,5598	22,6951	22,3792	22,5348	22,6646	22,3767	22,5616	22,2260	22,5951	22,2667
	7	22,9143	22,9380	23,2093	23,1380	23,0997	23,0441	23,0579	22,9931	22,8091	23,1167	22,9186	22,9943	22,7419	22,8490	22,9984	22,9843
	8	23,5383	23,2561	23,0604	22,8362	23,0320	23,3632	22,7760	24,1286	23,4061	23,1960	23,0861	22,9434	24,0517	23,3592	23,6449	24,0589
	9	23,5749	23,6684	23,7187	23,7152	23,7808	23,5966	23,7267	23,6803	23,6407	23,7303	23,6725	23,6875	23,7833	23,5656	23,6663	23,7074
	10	23,8585	23,6016	23,8515	24,0698	23,7531	24,0267	23,9801	23,9795	23,7140	23,8868	23,8118	23,5335	24,1476	23,7642	23,6833	24,1308
12	1	24,9677	25,0151	24,8305	25,0105	25,1295	25,0823	24,8974	25,3202	25,4099	25,0687	24,9954	25,1707	25,1492	25,1108	25,2230	25,2065
	2	25,1658	25,3020	24,7892	25,0772	24,9049	25,1032	25,1980	25,5681	25,5525	25,7930	25,2253	25,5367	25,5846	25,4584	25,6895	25,2514
	3	27,0403	27,1152	27,1346	27,1250	27,1660	27,1706	27,3371	27,5637	27,4247	27,6890	27,4791	27,4586	27,3330	27,3588	27,3749	27,4597
	4	25,0311	25,0817	25,2972	25,2408	24,9230	25,3959	25,2205	25,5546	25,5358	25,3231	24,9044	25,1956	25,2827	25,3181	25,6495	25,2154
	5	24,8636	24,9979	25,0027	25,1865	25,0063	25,2617	25,0557	24,9673	25,1432	25,0115	24,8321	24,8557	25,1113	24,9763	25,1584	25,0442
	6	23,7670	23,7805	24,0929	24,0723	24,1282	24,1211	24,0816	23,9495	24,1211	23,9746	23,8983	23,9194	23,9799	24,0876	23,8947	23,9954

Ek Tablo 5'in devamı

7	24,2452	24,2375	24,3840	24,4013	24,3835	24,3684	24,1722	24,2021	24,4817	24,5142	24,5275	24,2732	24,4395	24,6006	24,3708	24,5175
8	24,2407	25,2632	24,7521	24,7612	24,2790	24,6986	24,7286	25,5049	25,0213	25,0606	24,9951	25,1509	24,4529	24,2868	24,5154	25,0965
9	24,7161	24,6812	24,6360	24,8547	25,0244	24,9473	24,9084	24,8032	24,6769	24,8172	24,9547	24,7870	24,8508	24,9971	24,8715	24,9233
10	24,8910	25,0906	25,0179	25,2773	25,1493	25,1656	25,4605	25,4472	25,1608	25,0078	25,2691	25,5021	24,9944	25,0550	25,0484	25,1593

Ek Tablo 6. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların PSNR sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	15,1625	15,2770	15,3256	15,3466	15,2164	15,2387	15,3491	15,5304	15,5975	15,4812	15,4882	15,4198	15,4884	15,4133	15,5124	15,4844
	2	15,8580	15,8419	15,9059	15,6775	15,7792	15,8889	15,7149	16,2763	16,2331	16,2481	16,2278	16,2714	16,0282	16,1241	16,3275	16,3071
	3	18,8312	18,7187	18,9990	18,9096	18,9639	18,8894	18,9183	19,0999	19,1248	19,0846	19,0460	19,1391	19,0038	19,0935	19,0491	19,0683
	4	16,1560	15,9676	16,0999	16,3682	16,2356	16,3224	16,2484	16,5516	16,3927	16,3853	16,5926	16,5182	16,2473	16,4547	16,4086	16,4707
	5	14,1388	14,0996	14,3068	14,2462	14,2196	14,2217	14,2761	14,2338	14,1541	14,0872	14,0442	14,1589	14,0681	14,1139	14,1191	14,1702
	6	12,1174	12,0852	12,0715	12,3104	12,0496	12,2164	12,1916	12,3268	12,3262	12,2567	12,1544	12,3376	12,1964	12,2806	12,3479	12,3230
	7	13,1900	13,0601	13,0678	13,1455	13,0136	13,1623	13,1445	13,4912	13,3667	13,5745	13,2753	13,4767	13,3219	13,1358	13,4489	13,4178
	8	14,3463	14,4008	14,4669	14,2298	14,4760	14,5147	14,4775	14,6461	14,7367	14,6332	14,5281	14,6677	14,7214	14,3565	14,7766	14,8931
	9	15,1146	15,2450	15,3012	15,2932	15,2203	15,2995	15,1717	15,4147	15,4424	15,4443	15,4275	15,4648	15,4350	15,2630	15,4432	15,4514
	10	13,2285	12,9214	12,9068	13,1820	13,0311	13,1737	13,1771	13,2801	13,2868	13,2296	12,9981	13,0441	13,1546	13,3696	13,2398	13,3169
4	1	18,5098	18,4289	18,5215	18,6438	18,6707	18,6244	18,4525	19,0604	19,1515	18,9913	18,8293	18,7857	18,7661	18,9872	18,9845	19,0226
	2	18,4790	18,4872	18,3675	18,6735	18,4496	18,4749	18,7576	19,4196	19,3857	19,2454	18,7823	19,0342	18,8354	18,7704	19,1191	19,4121
	3	21,4392	21,4570	21,5907	21,4415	21,5165	21,7032	21,6008	21,8896	21,9377	21,7951	21,8086	21,7511	21,7538	21,6788	21,6895	21,9157
	4	19,1816	18,9718	19,1842	19,2367	19,1488	19,1897	19,2736	19,4144	19,3431	19,2119	19,3976	19,3221	19,3744	19,1288	19,6230	19,5406
	5	18,1040	18,2270	18,1433	17,9993	18,1367	18,1516	18,0781	18,1376	18,0618	18,1869	18,1710	18,0588	18,0437	18,2373	17,9441	18,1619
	6	15,7863	15,7989	16,2013	15,7809	15,9523	15,7138	15,5810	15,9420	15,9852	15,7311	15,8256	15,8626	16,0845	15,9402	15,8790	16,0691
	7	16,7489	16,8449	17,2016	16,8544	16,9138	16,9246	17,0826	17,2153	17,3413	17,5143	16,9083	17,1946	17,0768	17,1216	17,0247	17,4973
	8	17,6525	16,9319	16,8632	17,5732	17,1756	17,4628	17,1664	17,7098	17,5576	18,0568	17,5251	17,6721	17,6681	17,4987	18,2486	17,7134
	9	18,4801	18,4679	18,4917	18,6557	18,4475	18,3841	18,3513	18,6999	18,6483	18,6819	18,5368	18,6112	18,6008	18,5472	18,7360	18,6546
	10	17,9799	17,7412	18,1690	17,9655	17,9272	17,7816	17,8377	17,8326	17,7381	18,1745	17,6788	17,4147	17,9571	17,4642	17,9197	17,9752
6	1	20,6026	20,6858	20,8622	20,6641	20,9468	20,7693	20,7407	21,1846	20,9787	21,0351	21,0798	20,9991	21,0874	20,9057	21,1330	21,0977
	2	20,6469	20,8668	20,3637	20,5827	20,5413	20,6320	20,7076	21,5234	21,2703	21,5534	21,1010	21,1854	20,8990	20,9848	21,5322	21,2330
	3	23,2964	23,3293	23,3570	23,4338	23,4978	23,5251	23,3985	23,8188	23,8034	23,9088	23,7289	23,6853	23,8176	23,6341	23,7538	23,7534
	4	21,1774	21,1233	21,3076	21,1807	21,0126	21,1534	21,1195	21,5473	21,2967	21,5955	21,2289	21,3535	21,3525	21,2494	21,4840	21,4190
	5	20,4719	20,4625	20,7266	20,5317	20,4777	20,5746	20,5803	20,5299	20,4070	20,5689	20,6374	20,5833	20,3730	20,3666	20,6736	20,5871
	6	18,5757	18,7233	18,7088	18,7631	18,5126	18,7250	18,5560	18,5360	18,8586	18,6679	18,5628	18,6602	18,5570	18,6079	18,7196	18,5165
	7	19,2784	19,3943	19,5655	19,4339	19,5072	19,2109	19,3542	19,9145	19,5354	19,3422	19,6300	19,4481	19,5082	19,3130	19,9009	19,7937
	8	19,7202	19,9117	19,2134	20,1211	19,7301	19,5475	19,3136	20,6489	20,1046	20,4290	20,4383	20,1557	19,7811	19,2307	20,3987	20,4034
	9	20,5997	20,5178	20,5418	20,7675	20,7499	20,6480	20,7883	20,8620	20,8506	20,7065	20,6987	20,5579	20,8735	20,7282	20,6876	20,7685
	10	20,4611	20,3523	20,7632	20,4003	20,5926	20,6435	20,5387	20,4488	20,3185	20,5933	20,5468	20,5607	20,5821	20,3105	20,6793	20,1201
8	1	22,3617	22,3482	22,3372	22,3473	22,5753	22,4869	22,2378	22,6039	22,8164	22,8391	22,6442	22,7211	22,6038	22,5350	22,5947	22,6958
	2	22,3680	22,4383	22,4631	22,4123	22,1105	22,6942	22,2789	23,3315	23,4969	23,0376	22,8356	22,7127	22,8478	22,8174	22,9717	22,6163

Ek Tablo 6'nın devamı

	3	24,8977	24,9682	25,0399	25,0216	24,9749	24,9229	24,9229	25,1982	25,2205	25,2338	25,2428	25,2697	25,0311	25,0925	25,2271	25,1996
	4	22,5900	22,6226	23,0293	22,7696	22,8621	22,7569	22,7526	23,0859	22,9477	22,9335	22,6224	22,9905	22,8118	22,7991	22,8096	22,8624
	5	22,3368	22,3219	22,4018	22,3178	22,6209	22,4597	22,4369	22,1546	22,4235	22,2866	22,3120	22,3609	22,2023	22,3534	22,3859	22,4999
	6	20,5840	20,6599	20,9742	20,7452	20,8688	20,9147	21,2372	20,9279	20,7894	20,8770	21,0053	20,9852	20,6605	21,1193	21,0165	20,7624
	7	21,3264	21,1508	21,5737	21,6852	21,4973	21,6826	21,5145	21,7977	21,3902	21,7224	21,1948	21,5729	21,1592	21,1078	21,7269	21,4280
	8	20,8015	21,1121	21,7973	21,4484	21,8804	21,6214	21,4033	22,7374	22,1566	22,0726	21,6829	21,8198	21,0578	21,4735	21,9079	22,3296
	9	22,0610	22,3188	22,3527	22,4014	22,4893	22,2575	22,1568	22,3734	22,4124	22,4793	22,3439	22,3769	22,2731	22,2699	22,3902	22,3314
	10	22,3484	22,2652	22,4876	22,3357	22,3626	22,3035	22,2170	22,5969	22,3675	22,2711	21,9659	22,0593	22,0876	22,5347	22,0656	22,4522
10	1	23,6487	23,6458	23,6373	23,8585	23,6371	23,7987	23,6895	24,0753	24,1182	24,2816	23,9703	24,1023	24,0446	23,9159	24,0000	24,0374
	2	23,6857	23,0353	23,8483	23,4294	24,4085	23,7655	24,0202	24,5640	24,0156	24,7788	24,1626	24,1836	24,0341	23,6907	24,3570	24,2546
	3	26,0054	26,1793	26,1095	25,9624	26,1428	26,1091	26,0525	26,5922	26,4845	26,4484	26,3935	26,2974	26,6085	26,3750	26,3458	26,5162
	4	24,0691	24,0586	24,2512	24,0347	24,1150	24,1416	23,9857	24,2913	24,2979	24,2144	24,1078	24,1393	24,2611	24,0051	24,2312	24,3114
	5	23,7965	23,5266	23,8148	23,8722	23,8162	23,7407	23,8342	23,6912	23,6941	23,7480	23,5926	23,8713	23,8377	23,8470	23,8064	23,6435
	6	22,5633	22,5591	22,7721	22,4424	22,6501	22,3262	22,6157	22,4055	22,6498	22,5179	22,8430	22,5579	22,3774	22,1204	22,5114	22,5537
	7	23,0042	22,9253	22,9031	23,1090	23,0591	23,1371	22,9914	23,3181	23,1043	23,1965	22,6028	23,1773	23,1296	22,7652	23,1140	23,3018
	8	22,7403	22,8552	23,4285	23,2515	23,5030	23,4293	22,9895	23,9552	23,5150	23,5167	23,4173	23,5910	23,3116	23,0595	23,7532	23,5287
	9	23,5711	23,7747	23,7545	23,7178	23,7111	23,6694	23,8301	23,8799	23,6635	23,7674	23,8548	23,6934	23,5914	23,7088	23,6982	23,7449
	10	23,7510	23,9970	23,6182	23,9071	23,8722	24,2135	23,8297	23,9743	23,9895	23,8047	23,9378	23,7559	23,7458	23,8018	23,6413	23,7619
12	1	24,6003	24,7804	24,9665	24,9663	25,1271	25,0155	24,8206	25,2134	25,1692	25,2450	24,8976	25,0460	25,3220	24,9666	25,2025	25,1894
	2	25,4053	24,8573	25,4034	25,3208	25,5098	25,0441	24,9712	25,6840	25,6250	25,6427	25,4902	25,5163	25,4119	25,3403	25,6052	25,3614
	3	27,0258	27,1040	27,2259	26,9834	27,2282	27,0885	27,3326	27,4449	27,4220	27,4826	27,3435	27,3759	27,3429	27,5007	27,5468	27,5110
	4	25,0821	25,1874	24,8051	25,4008	25,1669	25,2244	25,1811	25,6549	25,4010	25,2712	25,3941	25,1844	25,2654	25,1523	25,1217	25,5502
	5	24,7930	24,7227	25,0688	25,0429	25,0488	24,9745	24,9453	25,1166	24,9608	24,9424	25,1614	25,1068	25,0144	25,1609	25,1272	24,9907
	6	24,0656	24,0719	23,8801	24,0133	23,5475	24,2666	24,0386	24,2730	23,6553	24,0167	24,0837	24,0078	23,9992	24,1291	24,0365	24,1607
	7	24,1717	23,9947	24,4249	24,4370	24,2369	24,3965	24,6315	24,3415	24,4285	24,2148	24,3451	24,2058	24,3824	24,3258	24,4031	24,2811
	8	24,2144	24,3018	24,8494	24,5189	24,9576	24,5088	24,5313	24,6426	24,8332	24,8639	24,9583	24,7537	24,5920	24,9038	24,5963	24,8425
	9	24,6203	24,8743	24,8615	24,9064	24,9376	25,0467	24,6955	25,0103	24,6589	24,7129	24,6673	24,7475	24,7071	24,9648	24,6914	24,7699
	10	25,2431	25,2552	25,4281	25,1722	25,3706	25,3360	25,2631	25,2717	25,0296	25,2850	25,0328	25,3567	25,3712	25,0239	25,2479	25,0805

Ek Tablo 7. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların PSNR sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	14,5879	14,7652	14,5569	14,6375	14,6729	14,7487	14,5131	14,7915	14,8142	14,7405	14,6539	14,6871	14,8020	14,7588	14,7662	14,7866
	2	13,8131	13,9674	13,9235	13,8942	13,8720	13,8136	13,8160	13,9835	13,9575	13,9841	13,9023	13,9037	13,8921	13,8395	13,9740	14,0052
	3	17,2507	17,3992	17,6861	17,4238	17,6812	17,7186	17,5392	17,9718	17,7891	18,0211	17,9606	17,9373	17,6666	17,8553	17,9930	18,0176
	4	14,5399	14,6741	14,5762	14,4842	14,5836	14,6272	14,5911	14,7330	14,7525	14,6145	14,3377	14,5650	14,6975	14,6285	14,5038	14,2836
	5	13,9402	13,9404	13,9464	13,9099	14,0070	13,9987	13,9027	14,0744	13,9421	14,0193	13,9743	13,9715	13,9844	13,9205	14,0401	14,0392
	6	12,3876	12,4809	12,3745	12,4211	12,4892	12,3351	12,4731	12,0655	12,0508	12,0982	12,1126	11,9226	12,1400	12,2842	11,9374	11,8695
	7	12,9487	12,8847	12,9837	13,2254	13,0684	13,0676	13,0379	13,4567	13,4353	13,3918	13,3472	13,2412	13,2336	13,1283	13,4135	13,4188
	8	12,6749	12,4880	12,4831	12,5459	12,5211	12,5752	12,6150	12,5397	12,5812	12,7780	12,6664	12,7133	12,6515	12,6913	12,7138	12,7997
	9	13,9918	13,8822	13,8520	13,5755	13,8775	13,8544	13,6221	14,0487	13,9595	14,0534	13,9974	13,8233	13,7605	13,8923	14,0518	14,0055
	10	13,3772	13,0821	13,3398	13,4504	13,2104	13,1586	13,4009	13,3091	13,2568	12,8500	13,3036	13,1237	13,3916	13,1982	12,9345	13,2060
4	1	17,4423	17,3004	17,7967	17,4482	17,5882	17,5898	17,6163	17,6758	17,6039	17,7621	17,5987	17,5962	17,8236	17,5440	17,5130	17,6655
	2	16,7166	16,5866	16,7768	16,1138	16,3311	16,4772	16,3968	16,9272	16,6596	16,7061	16,4213	16,8179	16,8277	16,4334	16,9530	17,2115
	3	20,1749	20,2933	20,2881	20,4352	20,4729	20,5449	20,4572	21,0768	21,0106	20,8233	20,6941	20,4385	20,4934	20,6376	20,7591	20,6090
	4	17,9949	17,5647	17,7136	17,6616	17,8669	17,6024	17,6246	17,8260	17,9138	17,5509	17,9123	17,7434	17,7807	17,8067	18,0387	17,7603
	5	17,4474	17,4664	17,2431	17,2242	17,0796	17,4404	17,1763	17,6586	17,5711	17,4760	17,5059	17,3972	17,2880	16,9839	17,4005	17,4505
	6	15,8922	15,5631	15,9872	15,7132	15,8589	16,0283	15,9328	15,2788	15,4808	15,2338	15,8220	15,7290	15,6279	15,6407	15,3219	15,5289
	7	16,8586	17,0254	16,9062	16,9918	16,8666	16,6895	16,9531	17,2552	17,2326	17,0004	16,8240	16,9388	16,8817	17,1758	16,8775	17,1885
	8	15,5181	15,3321	15,6145	15,4951	15,3437	15,3857	15,5123	15,7190	15,9143	15,9071	15,2867	15,5858	15,3078	15,3745	15,9117	15,7829
	9	17,3893	17,6156	17,5359	17,8670	17,5577	17,3340	17,4633	18,0097	17,8938	17,7647	17,9009	17,4775	17,6705	17,4323	17,7821	17,9912
	10	16,9475	16,9929	17,0037	17,2085	17,3222	16,9035	17,0796	17,0815	16,7317	16,7675	17,2047	17,3675	17,0091	17,0666	17,2875	16,8207
6	1	19,7220	19,6927	19,9204	19,3336	19,6720	19,6490	19,6007	19,6871	19,7700	20,1204	19,5428	19,6257	19,8797	19,5376	19,5563	19,6711
	2	19,0533	19,4297	18,7994	19,0422	18,7458	19,2887	19,2620	19,2972	19,3863	19,0279	19,2079	19,1763	19,5506	18,8762	18,9608	19,1303
	3	22,1067	21,8590	22,0773	22,4016	22,2324	22,3416	22,3458	22,6289	22,4715	22,6295	22,1044	22,2901	22,2647	22,0220	22,7929	22,3585
	4	19,2840	19,9258	20,1259	19,9931	19,6804	19,8906	19,5695	19,5808	20,0338	19,8305	19,7277	19,7561	19,9964	19,8127	19,8456	19,9946
	5	19,6283	19,1832	19,4352	19,4681	19,4293	19,4071	19,4618	19,3643	19,5180	19,0313	19,4139	19,7013	19,5123	19,4082	19,8575	19,4446
	6	18,5134	18,3349	18,7375	18,6358	18,5016	18,5380	18,7263	18,3705	18,1538	18,1208	18,5368	18,5857	18,4981	18,3390	17,9824	18,1820
	7	18,8807	19,3554	19,4398	19,1837	18,8468	19,2793	19,4946	19,3829	19,2336	18,9947	19,1913	19,1011	19,0184	19,2095	19,3730	19,2698
	8	18,7836	18,9071	19,0578	18,6980	18,0370	19,0612	18,9333	19,0205	18,8653	19,2280	18,8916	18,9587	18,8120	18,1654	18,7869	18,8494
	9	19,7004	20,0199	19,8702	19,6281	19,6732	19,7685	19,8011	20,2020	19,8996	20,0239	19,7986	19,6972	19,8625	19,6891	19,5055	19,9294
	10	19,2763	19,2650	19,4001	19,2677	19,7254	18,9865	19,6218	19,7125	19,1905	19,6224	19,8758	19,3982	19,7889	19,5775	19,5255	19,2595
8	1	21,3179	21,2580	21,1833	21,1376	21,4594	21,2652	21,3993	21,9077	21,4906	21,1585	21,3158	21,4130	20,9889	21,3548	21,2423	21,4541
	2	21,2001	21,0091	21,1549	21,2566	21,1192	21,1879	21,1199	20,6014	21,0902	20,9071	20,8585	21,4428	21,0522	21,4851	21,0708	20,6531

Ek Tablo 7'nin devamı

	3	23,5319	23,3663	23,4455	23,6396	23,6473	23,5469	23,4747	23,7233	23,9418	23,7543	23,4844	23,1670	23,6413	23,4996	23,5610	23,5616
	4	21,5738	21,1531	21,3038	21,2725	21,4700	21,6320	21,6833	21,5410	21,7217	21,5937	21,2316	21,3447	21,6049	21,4451	21,5245	21,8742
	5	21,1905	21,0350	21,0433	21,2151	20,8965	21,2165	21,2437	21,4904	21,5077	21,1483	21,2268	21,3344	21,0908	21,2784	21,3600	21,1308
	6	20,0671	20,6021	20,3555	20,4038	20,1690	20,2664	20,5630	19,9923	20,1510	20,2474	20,2596	20,7793	20,3317	20,5150	20,2150	20,4043
	7	20,5319	20,7847	21,2799	20,8523	20,9824	21,3370	20,5931	21,4428	21,2556	21,4460	21,1873	20,9663	21,0131	21,0495	21,2620	21,2283
	8	20,7930	20,5318	20,7151	21,4828	21,5138	20,8853	20,7920	20,8645	19,8839	20,6872	20,4607	20,6838	21,0627	20,9605	21,3916	21,4737
	9	21,3292	21,3942	21,6677	21,4522	21,3834	21,2895	21,4120	21,4395	21,4108	21,6983	21,2901	21,3233	21,5423	21,4608	21,4180	21,8285
	10	21,3064	20,7240	21,3529	21,5331	20,9860	21,0395	21,4259	21,5437	20,9962	21,0953	21,5443	21,6843	21,3842	21,4785	21,4183	21,3057
10	1	22,5187	22,5382	22,6593	22,8173	22,2986	22,4197	22,6944	22,6815	22,5967	22,5974	22,4954	22,6817	22,8237	22,6182	22,3914	22,9338
	2	22,0120	22,5554	22,7842	22,5294	22,4384	22,5944	22,4883	22,8606	22,5528	22,7157	22,5449	22,3206	22,5171	22,7983	22,6322	22,3991
	3	24,7143	24,3736	24,8449	24,4161	24,6898	24,5465	24,4966	24,8465	24,7871	24,7641	24,9365	24,7820	24,5244	24,6316	24,8008	24,8951
	4	22,5507	22,6449	22,8440	23,0292	23,1096	22,8371	22,8233	22,9007	23,0473	23,1010	22,7177	22,8977	23,1168	22,6291	23,0987	22,8356
	5	22,5057	22,6882	22,6961	22,6438	22,6817	22,9508	22,7438	22,5270	22,8027	23,0068	22,8745	22,5285	22,7142	22,5071	22,4428	22,6315
	6	21,6264	21,7687	22,2779	21,8263	21,9452	22,3161	21,9617	21,8022	22,2234	21,7909	22,0843	22,1608	21,8011	21,8222	21,9514	21,7791
	7	22,4818	22,3879	22,3908	22,6438	22,5003	22,4317	22,3001	22,1611	22,5829	22,6036	22,2781	22,4058	22,3170	22,4022	22,3110	22,3318
	8	22,7465	22,2772	22,6068	22,7623	22,6937	22,2573	22,7655	22,6563	22,0026	22,6148	22,5335	22,7341	22,7086	22,4033	22,5610	22,9475
	9	22,4118	22,5780	22,8119	22,7421	22,9796	22,7817	22,9503	22,6024	22,8402	22,7634	22,8670	22,6748	22,7195	22,8069	22,6441	22,4759
	10	22,2650	22,5151	22,3295	22,3190	22,1998	23,0571	22,6397	22,1893	23,3569	22,5465	22,8077	22,6097	22,4709	22,7157	22,5153	22,7518
12	1	23,6756	23,4007	23,6403	24,0477	23,7833	24,0102	23,9513	23,8730	23,8850	23,8054	23,6491	23,8580	23,7751	24,0190	23,5500	23,6455
	2	23,8414	23,7504	23,7447	24,0332	24,1170	24,0353	24,2988	23,8795	24,0492	24,2206	24,2680	23,8384	23,9941	23,7328	24,2136	23,7193
	3	25,5231	25,4435	25,6516	25,5493	25,4864	25,4519	25,2359	25,4763	25,5473	25,6451	25,6104	25,6545	25,3432	25,7501	25,6790	25,6195
	4	23,9771	24,2102	24,4018	23,9252	24,0740	24,4169	23,8901	24,0348	24,3737	23,9090	24,0684	23,8540	24,0982	23,8309	23,9301	24,2439
	5	24,1494	23,8063	23,9103	24,0507	23,6678	23,8613	23,7727	24,0642	23,6029	24,1172	23,9912	24,1855	24,0940	23,3947	23,9408	23,7402
	6	23,1682	23,3626	22,9921	23,3872	23,3111	23,3463	23,2450	23,3673	23,1081	23,2439	23,2219	23,2429	23,3379	23,1770	23,0941	22,9663
	7	23,7583	23,5355	23,2747	23,5920	23,6226	23,2691	23,6883	23,7350	23,2958	23,4910	23,3250	23,3586	23,6445	23,4170	23,3558	23,7302
	8	24,0199	23,6123	23,3525	23,9675	24,0120	23,9849	23,7511	24,2659	23,9836	24,0850	23,7740	24,2888	23,6547	23,4643	23,9043	23,7338
	9	23,7744	23,5832	23,8431	23,3995	23,6033	24,0067	24,0327	24,1951	23,7161	23,7946	23,6965	23,8929	24,0423	23,9151	23,9813	24,2287
	10	23,7560	23,8431	24,1856	23,4901	23,9230	23,7040	24,0746	24,2666	23,4913	24,0440	24,1269	23,8671	23,7909	23,8379	23,9872	23,4437

Ek Tablo 8. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların PSNR sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	14,6129	14,5642	14,6172	14,6106	14,7255	14,7276	14,6255	14,8848	14,8517	14,8631	14,9024	14,7807	14,8397	14,8363	14,8178	14,8387
	2	13,7483	13,7703	13,8222	13,8318	13,8911	13,8596	13,7725	13,9669	14,0631	13,9633	14,0374	13,9269	13,9549	13,9059	13,9137	13,9963
	3	17,4534	17,4705	17,4841	17,6821	17,7069	17,7313	17,6459	18,0162	17,9151	17,8883	17,9305	17,8716	17,7685	17,7640	17,9892	17,8819
	4	14,6072	14,8083	14,6359	14,5868	14,4139	14,6452	14,5362	14,7227	14,7876	14,7653	14,6725	14,4815	14,5742	14,6803	14,5485	14,8227
	5	14,0076	13,8974	14,0431	13,9344	13,9380	13,9433	14,1052	14,0390	13,9543	14,0042	13,9879	14,0041	13,9949	14,0194	14,0348	13,9645
	6	12,2675	12,3644	12,4072	12,4771	12,3241	12,3301	12,3862	11,8014	11,8842	12,0136	11,9742	11,9644	12,0278	11,9292	11,9149	11,9449
	7	12,9782	13,0633	13,0652	13,2049	13,1048	13,2070	13,0524	13,3104	13,3316	13,3848	13,4022	13,1557	13,3536	13,3503	13,4615	13,3475
	8	12,4030	12,5052	12,5470	12,5693	12,5142	12,4709	12,4637	12,7772	12,6651	12,6801	12,5967	12,5781	12,7054	12,6021	12,6712	12,6564
	9	13,7644	13,5799	13,6832	13,7099	13,7113	13,7376	13,8922	13,9764	14,1496	14,0263	14,0950	14,2556	13,6956	13,7540	13,9510	14,1176
	10	12,6771	13,4797	13,1942	13,4761	13,4945	13,2976	13,1258	13,2660	13,4959	13,4692	12,8230	13,1620	13,5291	13,4309	13,2701	13,3088
4	1	17,6239	17,6016	17,3077	17,4531	17,7325	17,3109	17,4774	17,6567	17,5422	17,8230	17,8460	17,6789	17,4419	17,5510	17,7993	17,8465
	2	16,2461	16,4485	16,7296	16,6259	16,5382	16,3794	16,4224	16,9941	17,1534	17,2922	16,5428	17,0946	16,6200	16,7719	17,0483	17,0198
	3	20,3306	20,2584	20,4492	20,4111	20,2955	20,3419	20,4434	21,0455	20,8444	20,9466	20,7705	20,9983	20,2960	20,3422	20,8923	20,8922
	4	17,6028	17,3814	17,6967	17,7273	17,7301	17,9290	17,4749	17,9801	17,9764	18,0872	17,7086	18,2405	17,6632	17,5482	18,0499	17,5386
	5	17,3224	17,2017	17,4573	17,3960	17,4840	17,3734	17,5559	17,4830	17,4718	17,4427	17,5898	17,7055	17,3283	17,2256	17,6367	17,6356
	6	16,0471	15,8829	15,8855	15,9314	15,8500	16,1586	15,7948	15,3385	14,9220	14,8928	15,3503	15,4613	15,6035	15,7301	15,4561	15,4922
	7	16,8490	16,7591	16,7759	16,8998	16,6311	16,8043	17,0523	17,2767	17,0731	16,9791	16,8455	16,7260	16,9554	16,8364	17,0171	17,1645
	8	15,8030	15,7924	15,3758	15,6128	15,5649	15,5214	15,4667	15,9172	16,2215	16,0860	15,9815	15,6145	15,6263	15,6936	15,5145	15,8111
	9	17,6611	17,3697	17,4939	17,5863	17,4758	17,5223	17,7007	17,9264	17,8437	17,8336	17,8486	17,5852	17,8739	17,4543	17,8000	17,7722
	10	17,2476	16,9185	17,2799	17,2323	17,4503	17,3443	17,2782	16,8563	16,9670	17,0423	16,7642	16,7067	17,0203	17,3970	16,6959	16,9538
6	1	19,8010	19,3124	19,6977	19,5985	19,6416	19,7741	19,7596	19,5841	19,8218	19,6353	19,6773	19,9892	19,9806	19,6569	19,6537	19,9601
	2	19,1117	19,5015	19,0204	19,1418	19,1270	18,5559	19,0371	19,7507	19,5510	19,2913	19,5819	19,2270	19,4351	19,2661	19,7446	19,4726
	3	22,0815	22,1871	22,3059	22,2384	22,0581	22,1181	22,0206	22,5910	22,5726	22,5692	22,4033	22,2089	22,3637	22,0934	22,4364	22,5743
	4	20,1130	19,6868	19,8649	19,7848	19,6155	20,1950	20,0714	20,1943	20,0787	19,7942	20,2381	19,8716	19,6934	19,5142	20,1784	19,6336
	5	19,2641	19,1788	19,5530	19,3638	19,4769	19,2828	19,3575	19,5129	19,6180	19,1816	19,3215	19,3446	19,3490	19,3598	19,8203	19,3608
	6	18,4157	18,4380	18,3323	18,4908	18,3058	18,5087	18,4985	18,3113	18,2435	18,1670	18,5009	18,0919	18,2202	18,2437	18,1538	18,0602
	7	19,3849	19,1869	19,2382	19,1975	19,1317	19,1299	19,2324	19,4510	19,1047	19,4522	19,0501	19,3569	19,4170	19,4169	19,2534	19,2926
	8	18,7282	18,7778	19,1286	18,6382	18,0995	18,4936	18,4293	19,1709	18,6776	18,8733	18,4709	18,7173	18,6586	18,9134	19,4712	19,0992
	9	19,3320	19,7096	19,6072	19,7056	19,7854	19,9388	19,5825	20,2093	19,8098	19,8170	19,7501	19,7396	19,5851	19,9296	19,9899	20,0550
	10	19,2968	19,4832	19,7984	19,5966	19,9452	19,3432	19,3612	18,9986	19,6432	19,5781	19,1674	19,3428	19,6711	19,4540	19,5470	19,2711
8	1	21,4440	21,3185	21,3324	21,1526	21,6075	21,1305	21,3741	21,3919	21,8081	21,1848	21,2648	21,6099	21,3048	21,1764	21,4260	21,3825
	2	21,5700	20,9697	21,0923	21,3363	20,8943	20,9296	20,9989	21,2512	21,5613	21,4794	21,1216	20,9907	21,2406	21,3928	20,7069	21,2393

Ek Tablo 8'in devamı

	3	23,3730	23,6477	23,1199	23,8231	23,3001	23,5323	23,0888	24,1593	23,5892	23,6420	23,4451	23,7675	23,7300	23,5645	23,7160	23,7699
	4	21,3614	21,0004	21,6536	21,2630	21,3608	21,4291	21,6981	21,5682	21,5849	21,6265	21,6645	21,7589	21,6820	21,2705	21,4486	21,8302
	5	21,1352	20,9563	21,4972	21,3464	21,2541	21,1022	20,9271	21,2675	21,3169	21,3328	21,1822	21,0938	21,2787	20,8246	21,0923	20,9674
	6	20,2432	20,3957	20,0784	20,6778	20,3089	20,3551	20,4884	20,1645	20,2736	20,3625	20,3870	20,2071	20,2822	20,6707	20,0799	20,0976
	7	20,9001	20,7571	20,9968	20,9081	21,1231	21,0409	21,1286	21,1640	20,9496	20,9863	20,9715	21,1788	20,9900	20,8749	20,9264	21,0826
	8	20,7639	20,7117	20,8159	20,9597	20,9470	20,7865	20,8350	21,3665	21,3180	20,9904	20,8310	20,2969	20,7835	20,2382	20,8402	21,2434
	9	21,2473	21,5233	21,3215	21,3698	21,3993	21,2448	21,2866	21,3825	21,5585	21,4757	21,5283	21,5377	21,6533	21,2214	21,5146	21,3284
	10	21,4563	21,1958	21,1786	21,3568	21,4862	21,3718	21,2109	20,6269	20,8054	21,1111	21,3240	20,9054	20,8074	21,4658	20,7500	20,8494
10	1	22,6593	22,3372	22,6753	22,5712	22,5018	22,6889	22,5964	22,8048	22,4591	22,6800	22,5938	22,8664	22,7511	22,2331	22,4467	22,9212
	2	22,8502	22,1691	22,3891	22,0211	22,5277	22,7787	21,9024	22,8580	22,7429	22,7854	22,6597	22,2313	22,5751	22,8847	22,7630	22,6814
	3	24,7939	24,6309	24,6926	24,5753	24,6669	24,4350	24,3601	24,6607	24,9120	24,8156	24,5569	24,3497	24,8753	25,0083	24,7026	24,6498
	4	23,0328	22,6568	23,0094	22,8949	22,7486	23,0452	22,8212	22,9680	23,0261	22,7637	22,9843	22,6022	22,7904	23,3760	23,2074	22,5013
	5	22,6748	22,6583	22,6538	22,5652	22,6037	22,4307	22,6984	22,6635	22,6907	22,8073	22,8093	23,0557	22,3958	23,0030	22,6901	22,7449
	6	21,9503	21,4305	21,8012	21,8741	21,8116	22,2074	21,7514	21,9217	21,7645	22,1008	22,0921	22,0286	21,7694	21,8582	21,8134	21,7886
	7	22,0705	22,2911	22,6979	22,2356	22,4118	22,0485	22,6155	22,2945	22,2953	22,4957	22,4751	22,2346	22,0529	22,5146	22,5144	22,6034
	8	22,1943	22,3843	22,8340	22,8447	22,7528	22,9330	22,2827	22,2586	22,3117	22,9641	22,6879	22,0754	22,1709	22,2987	22,0437	22,4130
	9	22,6575	22,8900	22,4173	22,7704	22,4924	22,5303	22,9083	22,6255	22,9474	22,6522	22,4873	22,6010	22,6853	22,3631	22,4850	22,4841
	10	23,0950	22,6301	22,8054	22,6991	22,7099	22,7134	22,5981	22,2149	22,1703	22,7940	22,5786	22,5947	22,3921	22,8255	22,6999	22,8392
12	1	23,4215	23,7387	23,8727	24,0995	23,7950	23,9044	23,5066	23,8319	23,6609	23,5688	23,9468	24,0703	23,9845	23,9818	24,0972	23,8181
	2	23,5535	23,7132	23,8792	23,2303	23,4399	24,0344	23,5614	24,3568	23,9149	23,8843	23,8800	23,8600	23,4040	23,8500	23,6551	23,7902
	3	25,3613	25,3994	25,7921	25,7497	25,7795	25,6995	25,6536	25,6513	25,6828	25,6346	25,8847	25,7353	25,6332	25,6634	25,8860	25,8288
	4	24,0154	24,1424	23,8881	24,0623	23,9956	24,2096	24,1449	24,1574	23,6930	23,8779	24,0804	23,8009	24,1131	24,2573	24,1543	23,9843
	5	23,9155	23,9586	23,9476	23,8056	23,7832	24,0594	24,1313	23,9987	23,7797	23,7619	23,7322	24,2461	23,8869	23,9192	23,7128	24,0064
	6	23,1050	23,4325	23,2870	23,1462	23,2465	23,4706	23,5797	22,9469	22,8565	23,3689	23,5044	22,8655	23,1529	23,2687	22,8222	23,3582
	7	23,3936	23,6269	23,4854	23,5156	23,6632	23,3861	23,7140	23,9234	23,2469	23,7619	23,5612	23,3327	23,7117	23,5100	23,6615	23,7446
	8	23,9517	23,8954	23,8516	24,0212	23,8935	23,5674	23,6787	23,6390	23,8910	24,0490	23,7333	24,2301	23,3835	23,6018	23,9477	23,7220
	9	23,6122	23,7128	23,9726	24,0872	23,8939	24,2390	24,0621	24,1920	23,8536	24,0627	23,9638	24,2425	23,9008	23,9472	23,8999	23,7483
	10	23,6387	23,9534	23,9931	23,8164	24,2474	23,7431	23,6887	23,9697	24,2134	23,8756	23,6262	23,8736	24,1010	23,1810	23,7601	23,4585

Otsu Yöntemi:

- Ek Tablo 9 ($maxFEs = 500 \times m$): WChOA ve WChOA-UMD yöntemleri, 60 deneyin 55'inde en yüksek SSIM değerlerini elde etmiştir.
- EK Tablo 10 ($maxFEs = 1000 \times m$): En yüksek SSIM değerleri 60 deneyin 56'sında kaydedilmiştir.

Kapur Entropisi:

- EK Tablo 11 ($maxFEs = 500 \times m$): Önerilen yöntemler, 60 deneyin 43'ünde rakiplerini geride bırakmıştır.
- EK Tablo 12 ($maxFEs = 1000 \times m$): Başarılı deney sayısı 60 deneyin 49'una yükselmiştir.

Ek Tablo 9. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların SSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,338148	0,344692	0,354684	0,341500	0,329854	0,343823	0,348720	0,359361	0,361554	0,365003	0,367183	0,362024	0,350578	0,363113	0,361033	0,370814
	2	0,273690	0,282606	0,301453	0,284759	0,291538	0,280278	0,295178	0,337171	0,323250	0,327460	0,317014	0,326089	0,324835	0,309113	0,316936	0,331553
	3	0,323862	0,317125	0,312936	0,311359	0,322127	0,311388	0,316564	0,342081	0,341869	0,338567	0,328194	0,334490	0,340083	0,330859	0,350282	0,338249
	4	0,461502	0,462856	0,470171	0,474929	0,458202	0,459118	0,471115	0,509044	0,506008	0,508892	0,505667	0,501580	0,499655	0,493392	0,508766	0,509709
	5	0,465150	0,457549	0,462514	0,464856	0,459636	0,462129	0,467494	0,476776	0,475251	0,476677	0,471124	0,470148	0,469668	0,469876	0,475098	0,471524
	6	0,542709	0,535890	0,536087	0,542780	0,534626	0,536386	0,537743	0,542189	0,544367	0,542445	0,541471	0,550359	0,540060	0,547005	0,549359	0,538674
	7	0,532847	0,540684	0,538275	0,541239	0,528841	0,530841	0,532016	0,552765	0,549215	0,556456	0,544014	0,538200	0,552591	0,539041	0,553359	0,548959
	8	0,349464	0,347637	0,358122	0,359711	0,341593	0,347780	0,357175	0,373743	0,382001	0,374937	0,365701	0,364149	0,366443	0,371640	0,379614	0,366784
	9	0,404200	0,401784	0,413184	0,416857	0,410227	0,401179	0,411350	0,426589	0,431533	0,434253	0,419071	0,426626	0,439432	0,421340	0,425859	0,434459
	10	0,644016	0,645683	0,660903	0,659467	0,648508	0,645244	0,660586	0,668270	0,661718	0,664884	0,659299	0,658438	0,656447	0,660340	0,662420	0,652247
4	1	0,514476	0,547704	0,531828	0,536736	0,541914	0,535936	0,535906	0,569103	0,587653	0,601471	0,562616	0,578253	0,563838	0,587629	0,575158	0,571813
	2	0,475873	0,485079	0,467004	0,458499	0,463213	0,460819	0,466289	0,523910	0,522561	0,515501	0,483427	0,494868	0,497587	0,488934	0,516451	0,508975
	3	0,438745	0,437193	0,450090	0,433327	0,450657	0,432004	0,445418	0,527930	0,523602	0,520088	0,516305	0,504063	0,509961	0,498124	0,525817	0,520020
	4	0,595775	0,606694	0,601916	0,614852	0,602694	0,602258	0,607297	0,630004	0,634791	0,634869	0,620760	0,604451	0,626137	0,616148	0,631413	0,640770
	5	0,598420	0,605570	0,608007	0,602418	0,594078	0,603440	0,598827	0,620241	0,623527	0,615618	0,610568	0,600673	0,610736	0,605341	0,609054	0,616562
	6	0,647679	0,646950	0,651878	0,646362	0,646537	0,640394	0,645179	0,656551	0,647758	0,638756	0,631389	0,637440	0,649474	0,638843	0,646992	0,633031
	7	0,724137	0,723510	0,727587	0,731109	0,738204	0,727444	0,729172	0,737989	0,732690	0,730984	0,725167	0,732157	0,729007	0,736846	0,741325	0,740139
	8	0,501661	0,531216	0,545143	0,524140	0,517831	0,516274	0,508428	0,562640	0,548662	0,569980	0,544365	0,524183	0,554165	0,515446	0,556332	0,546399
	9	0,594332	0,579307	0,584614	0,588340	0,572270	0,572283	0,574361	0,600505	0,599688	0,602837	0,606870	0,588949	0,583318	0,582642	0,608119	0,608864

Ek Tablo 9'un devamı

	10	0,779804	0,787006	0,789173	0,783248	0,782410	0,786221	0,788533	0,789376	0,790473	0,786548	0,779011	0,785244	0,787671	0,781119	0,781688	0,793672
6	1	0,642867	0,662014	0,648927	0,648064	0,647533	0,646608	0,624145	0,682269	0,681869	0,673037	0,676217	0,675282	0,679479	0,653029	0,685191	0,671989
	2	0,574427	0,597726	0,568183	0,596414	0,593663	0,597818	0,591525	0,631673	0,639173	0,636087	0,638054	0,627265	0,610065	0,606607	0,629628	0,626830
	3	0,538391	0,537569	0,533243	0,534185	0,543125	0,539986	0,555523	0,622186	0,607280	0,619897	0,624386	0,621616	0,634253	0,592363	0,629838	0,618241
	4	0,676838	0,690573	0,677113	0,685372	0,672231	0,669404	0,681348	0,711837	0,707387	0,706276	0,691282	0,702090	0,693904	0,681469	0,709554	0,717729
	5	0,668361	0,670978	0,669613	0,669788	0,667788	0,671591	0,667119	0,688393	0,689686	0,676694	0,673802	0,671561	0,678776	0,665317	0,686519	0,687842
	6	0,712158	0,714512	0,713063	0,714502	0,702657	0,717108	0,717364	0,719820	0,705216	0,711350	0,712572	0,702307	0,702868	0,718567	0,709370	0,725687
	7	0,825585	0,807225	0,821306	0,808489	0,814644	0,822359	0,815472	0,827143	0,820483	0,825464	0,817579	0,818350	0,827796	0,817332	0,818783	0,819868
	8	0,607881	0,645074	0,660049	0,646693	0,648124	0,648452	0,644274	0,677976	0,655286	0,665572	0,649117	0,667361	0,657812	0,658823	0,642569	0,661232
	9	0,660105	0,678985	0,666703	0,676113	0,676190	0,671514	0,668563	0,686376	0,687527	0,689287	0,671806	0,681101	0,684286	0,669062	0,687009	0,683052
	10	0,816010	0,816779	0,817496	0,821897	0,815189	0,819405	0,819953	0,818432	0,822334	0,821060	0,817844	0,819690	0,817402	0,817720	0,819632	0,814053
8	1	0,707210	0,702848	0,723418	0,718355	0,719066	0,706248	0,715433	0,757564	0,752073	0,755198	0,734608	0,727128	0,742224	0,729752	0,740816	0,735128
	2	0,660358	0,673837	0,671283	0,660961	0,675013	0,673012	0,669573	0,695614	0,713364	0,708405	0,687538	0,687161	0,684571	0,695882	0,721674	0,691798
	3	0,600426	0,602431	0,605681	0,601119	0,621989	0,635197	0,607779	0,711592	0,676612	0,697149	0,662859	0,696609	0,665430	0,677280	0,694304	0,694527
	4	0,727294	0,736830	0,731032	0,735715	0,734796	0,746684	0,735033	0,751418	0,760406	0,769601	0,754790	0,737612	0,759989	0,743691	0,753973	0,748936
	5	0,705237	0,718764	0,716055	0,717629	0,720970	0,714624	0,718540	0,729047	0,733866	0,728383	0,727123	0,719249	0,721288	0,717266	0,731912	0,726472
	6	0,766872	0,755260	0,754635	0,753506	0,763430	0,754499	0,756993	0,764063	0,761990	0,758536	0,756448	0,755317	0,767924	0,760356	0,758605	0,750887
	7	0,870325	0,869276	0,866601	0,862111	0,860353	0,868023	0,872420	0,873889	0,872635	0,869550	0,865698	0,862567	0,870597	0,866988	0,868594	0,864468
	8	0,720485	0,705299	0,715648	0,711203	0,703817	0,719292	0,711153	0,728000	0,757186	0,731517	0,716313	0,742238	0,721131	0,730469	0,728652	0,733329
	9	0,720418	0,720617	0,730635	0,731178	0,721266	0,725700	0,730391	0,737387	0,730509	0,735073	0,737574	0,734554	0,734314	0,719103	0,736909	0,745075
	10	0,833958	0,840585	0,840487	0,836299	0,846903	0,837305	0,842684	0,836561	0,844696	0,845599	0,839604	0,845895	0,844602	0,843680	0,840549	0,842971
10	1	0,753467	0,752232	0,767401	0,764281	0,771435	0,759232	0,757771	0,798012	0,784285	0,789155	0,765005	0,785780	0,780721	0,767604	0,789983	0,798174
	2	0,763421	0,717500	0,734414	0,737804	0,739166	0,733930	0,748324	0,758209	0,753687	0,769092	0,741317	0,743314	0,734495	0,741306	0,753940	0,742807
	3	0,685210	0,663292	0,674476	0,685058	0,681987	0,671624	0,658565	0,743351	0,756286	0,755545	0,737467	0,751607	0,729558	0,740146	0,741409	0,751133
	4	0,772975	0,781448	0,774531	0,778580	0,773854	0,775255	0,784731	0,796955	0,792639	0,802448	0,773981	0,788347	0,784472	0,783292	0,786947	0,790944
	5	0,753673	0,753841	0,754651	0,749232	0,746618	0,748714	0,750593	0,757002	0,750991	0,760690	0,749795	0,753142	0,749579	0,745379	0,757245	0,758879
	6	0,789131	0,796252	0,790693	0,788653	0,790318	0,785675	0,791846	0,792500	0,794320	0,791107	0,788366	0,789840	0,791942	0,785524	0,792640	0,787852
	7	0,894349	0,896545	0,902007	0,899790	0,899581	0,898989	0,899036	0,898911	0,893958	0,901219	0,895764	0,897568	0,892297	0,895188	0,897638	0,897979
	8	0,782661	0,773243	0,765409	0,755185	0,765366	0,770613	0,752752	0,799852	0,775007	0,766613	0,760157	0,759278	0,796544	0,777716	0,785057	0,800109
	9	0,776155	0,764346	0,769184	0,777651	0,776071	0,770089	0,776976	0,766497	0,774871	0,774427	0,772012	0,765212	0,773578	0,764510	0,768449	0,775962
	10	0,860978	0,861763	0,858096	0,865044	0,855552	0,864461	0,861118	0,860322	0,860119	0,864170	0,864113	0,859160	0,867902	0,856990	0,860193	0,861893
12	1	0,805444	0,800414	0,791256	0,807501	0,804763	0,809641	0,797236	0,822288	0,830434	0,814641	0,810848	0,817615	0,816407	0,811681	0,824168	0,817971
	2	0,780719	0,785721	0,764311	0,771949	0,770184	0,769591	0,779901	0,798175	0,797856	0,806464	0,779281	0,795957	0,789369	0,792067	0,803715	0,784303
	3	0,723441	0,731434	0,732504	0,719170	0,716120	0,727468	0,735324	0,788940	0,780182	0,798717	0,789312	0,784992	0,772922	0,768311	0,772848	0,799651
	4	0,799563	0,802308	0,810125	0,801443	0,787249	0,809862	0,813737	0,826340	0,821044	0,822491	0,802419	0,809647	0,804615	0,809453	0,822630	0,807370
	5	0,773895	0,774870	0,777459	0,776725	0,774335	0,774475	0,775827	0,776273	0,785638	0,777739	0,767660	0,777434	0,772775	0,777130	0,781218	0,781761
	6	0,811953	0,811427	0,819806	0,818525	0,819250	0,819904	0,818491	0,815387	0,818607	0,819015	0,817530	0,818387	0,815800	0,819108	0,812020	0,819003

Ek Tablo 9'un devamı

7	0,917282	0,917603	0,920329	0,919848	0,920597	0,918358	0,917049	0,917404	0,921309	0,922250	0,922206	0,918716	0,919323	0,923406	0,919878	0,921404
8	0,798128	0,833554	0,810598	0,814188	0,798735	0,813607	0,812490	0,835980	0,822829	0,826697	0,819500	0,825825	0,802857	0,797551	0,807629	0,825284
9	0,802569	0,792545	0,790181	0,804737	0,807445	0,812556	0,803320	0,809571	0,799876	0,801500	0,808964	0,804691	0,796527	0,818386	0,803474	0,805134
10	0,876163	0,872974	0,875488	0,878535	0,875365	0,875926	0,879496	0,878333	0,877047	0,872740	0,874977	0,879635	0,874925	0,876493	0,875565	0,875621

Ek Tablo 10. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların SSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,340742	0,346628	0,353259	0,352180	0,341615	0,334927	0,349455	0,369079	0,373425	0,362959	0,367446	0,355438	0,372506	0,361285	0,362528	0,363992
	2	0,294319	0,296022	0,301157	0,283770	0,293285	0,299715	0,284258	0,327999	0,324270	0,327330	0,328852	0,327907	0,310454	0,318227	0,336658	0,332872
	3	0,317006	0,316896	0,315932	0,317306	0,320206	0,319155	0,315035	0,342969	0,338208	0,344639	0,340836	0,337038	0,335986	0,327993	0,343600	0,341090
	4	0,457782	0,452541	0,450768	0,484360	0,472187	0,476273	0,469186	0,510322	0,509908	0,507582	0,504425	0,506747	0,500496	0,498045	0,507817	0,510015
	5	0,456958	0,456071	0,461908	0,465264	0,460898	0,465183	0,462295	0,478149	0,476090	0,476173	0,470768	0,475355	0,471503	0,471430	0,476052	0,477417
	6	0,541908	0,536676	0,535922	0,550048	0,532958	0,542279	0,538739	0,548969	0,547992	0,545998	0,536687	0,553086	0,542569	0,545482	0,553647	0,548869
	7	0,536155	0,526657	0,528302	0,531980	0,533353	0,542493	0,535779	0,555817	0,547981	0,557328	0,548266	0,548542	0,548513	0,535651	0,551890	0,555968
	8	0,348826	0,352147	0,356277	0,341554	0,357685	0,356630	0,359326	0,372441	0,374969	0,372577	0,363271	0,367690	0,374711	0,350817	0,376648	0,385658
	9	0,404131	0,412852	0,410831	0,406000	0,397406	0,426133	0,397783	0,428633	0,434475	0,428881	0,427443	0,426913	0,429577	0,410930	0,436069	0,427663
	10	0,660563	0,648893	0,651857	0,664675	0,656923	0,659016	0,661128	0,670409	0,667695	0,666146	0,655751	0,661892	0,658726	0,673076	0,666530	0,666699
4	1	0,536235	0,528338	0,541682	0,542965	0,536346	0,539460	0,532105	0,586086	0,591265	0,588064	0,569229	0,564001	0,554451	0,567482	0,583523	0,583147
	2	0,460537	0,462747	0,452202	0,475651	0,454592	0,465625	0,481795	0,541716	0,533356	0,526705	0,496261	0,510472	0,497918	0,483477	0,518041	0,536946
	3	0,441418	0,450013	0,454113	0,447073	0,446585	0,448084	0,441295	0,531127	0,515969	0,513960	0,534883	0,517646	0,527170	0,502820	0,539460	0,528896
	4	0,607983	0,590567	0,599498	0,594842	0,605972	0,611640	0,613246	0,648093	0,642495	0,651818	0,632695	0,635059	0,629376	0,620042	0,628818	0,651487
	5	0,593341	0,597131	0,596433	0,600215	0,596385	0,600881	0,604358	0,624775	0,615848	0,622361	0,619035	0,619785	0,621998	0,607938	0,616147	0,619819
	6	0,645845	0,638191	0,650706	0,639100	0,643645	0,636429	0,632806	0,645424	0,644169	0,638730	0,637683	0,646656	0,646656	0,645501	0,643523	0,648920
	7	0,718779	0,722058	0,739895	0,725824	0,726961	0,728112	0,734317	0,740170	0,744713	0,755748	0,729825	0,742082	0,736652	0,737737	0,736236	0,750756
	8	0,540252	0,507538	0,501095	0,539592	0,512860	0,537727	0,519436	0,550835	0,539169	0,567996	0,539756	0,544733	0,542470	0,540466	0,578097	0,548039
	9	0,577559	0,581703	0,593116	0,588206	0,579880	0,576392	0,571844	0,609911	0,607246	0,604893	0,604930	0,599282	0,598252	0,592618	0,616662	0,609969
	10	0,785586	0,785256	0,790757	0,786865	0,788209	0,791347	0,788709	0,795088	0,782408	0,795065	0,785861	0,784387	0,786323	0,782507	0,787527	0,790977
6	1	0,633394	0,641702	0,647478	0,635142	0,653270	0,654863	0,646443	0,690452	0,676299	0,679125	0,677151	0,665441	0,677395	0,671929	0,688214	0,686008
	2	0,584902	0,599212	0,570107	0,580689	0,580048	0,587367	0,593372	0,654381	0,629449	0,648515	0,617550	0,621644	0,603111	0,608308	0,643001	0,624744
	3	0,540900	0,542206	0,541188	0,542985	0,554060	0,539474	0,543789	0,635735	0,630145	0,629563	0,638280	0,622244	0,615025	0,602668	0,619254	0,642622
	4	0,675581	0,680334	0,684673	0,696405	0,683154	0,679486	0,664078	0,721575	0,714786	0,708024	0,690966	0,708355	0,702380	0,686723	0,710579	0,708770
	5	0,664438	0,670544	0,681207	0,674522	0,668581	0,678372	0,673159	0,682108	0,691388	0,697030	0,678384	0,683895	0,672675	0,680795	0,698471	0,694019
	6	0,708552	0,712766	0,711563	0,709377	0,706600	0,710228	0,709330	0,710587	0,713946	0,706616	0,705654	0,708183	0,705478	0,707169	0,716983	0,709047
	7	0,808094	0,813337	0,818896	0,813799	0,817515	0,807768	0,812737	0,830919	0,820265	0,813662	0,823560	0,815274	0,818431	0,811311	0,828279	0,826785
	8	0,639175	0,651137	0,616064	0,659006	0,638613	0,637900	0,624596	0,684464	0,667286	0,677498	0,676033	0,658302	0,642664	0,620450	0,675675	0,675046
	9	0,672262	0,655702	0,664784	0,679108	0,681103	0,662665	0,684579	0,689318	0,696852	0,689739	0,676303	0,680171	0,679359	0,677552	0,701010	0,685032
	10	0,825825	0,823911	0,821272	0,823768	0,824962	0,827181	0,818499	0,821027	0,817023	0,821067	0,820375	0,817831	0,823450	0,821247	0,828106	0,812854
8	1	0,715652	0,712546	0,707943	0,711936	0,719344	0,718987	0,700191	0,745987	0,744710	0,755148	0,735935	0,749994	0,739791	0,731494	0,736881	0,740493
	2	0,665822	0,680729	0,674199	0,678940	0,653295	0,681189	0,662722	0,731020	0,736638	0,718678	0,697782	0,688972	0,691227	0,696635	0,707731	0,685064

Ek Tablo 10'un devamı

	3	0,620492	0,623612	0,606482	0,631136	0,624614	0,623436	0,620270	0,704639	0,701769	0,702900	0,684107	0,701907	0,701053	0,680681	0,707708	0,704807
	4	0,735479	0,743179	0,745670	0,734057	0,744793	0,733871	0,725869	0,772624	0,767641	0,768251	0,742672	0,752958	0,750159	0,729426	0,759432	0,762881
	5	0,717275	0,721445	0,718048	0,712173	0,725461	0,717187	0,719751	0,738296	0,725908	0,734620	0,721667	0,722967	0,728318	0,716231	0,725989	0,733528
	6	0,750804	0,754160	0,759239	0,754144	0,759706	0,760749	0,764323	0,761210	0,756542	0,764307	0,761865	0,760078	0,753613	0,766902	0,760270	0,756796
	7	0,863905	0,860017	0,869665	0,873947	0,867963	0,871208	0,867463	0,876958	0,866806	0,871802	0,861417	0,869049	0,858403	0,858115	0,878254	0,868018
	8	0,686538	0,694334	0,723494	0,708999	0,728743	0,716902	0,713308	0,761872	0,737473	0,734732	0,721579	0,726963	0,690898	0,711066	0,729510	0,743427
	9	0,706948	0,722540	0,729563	0,726611	0,733004	0,727630	0,709008	0,742751	0,731858	0,745288	0,726840	0,727804	0,727516	0,729912	0,736993	0,745516
	10	0,842908	0,838463	0,845222	0,842353	0,845704	0,840353	0,841922	0,845619	0,837703	0,843267	0,841778	0,838991	0,837665	0,846015	0,839469	0,844778
10	1	0,757305	0,753382	0,751080	0,763698	0,756264	0,763601	0,757974	0,794539	0,789298	0,798110	0,781653	0,788143	0,783702	0,772939	0,789417	0,786175
	2	0,722660	0,691499	0,723469	0,707386	0,755046	0,721450	0,739165	0,772081	0,738071	0,776834	0,740914	0,750721	0,739591	0,719353	0,758849	0,755775
	3	0,671359	0,678960	0,670460	0,661260	0,679240	0,683195	0,676550	0,757220	0,757927	0,743225	0,743339	0,754405	0,756921	0,733309	0,751824	0,754572
	4	0,783095	0,787467	0,782766	0,754848	0,775656	0,771854	0,771435	0,804504	0,797951	0,811076	0,783025	0,786790	0,789641	0,778262	0,797047	0,787333
	5	0,747465	0,745082	0,750878	0,752979	0,751912	0,746384	0,753032	0,759715	0,754483	0,759068	0,752945	0,755084	0,750100	0,755608	0,761732	0,750143
	6	0,791243	0,793239	0,793564	0,790788	0,791623	0,788635	0,789131	0,789925	0,792116	0,793118	0,796805	0,789955	0,785888	0,782580	0,793886	0,791628
	7	0,897539	0,896319	0,894974	0,901316	0,900748	0,899859	0,898729	0,905524	0,900522	0,900470	0,889959	0,901003	0,901099	0,893729	0,899783	0,904827
	8	0,753427	0,757974	0,774208	0,773609	0,780823	0,778666	0,757894	0,800431	0,783095	0,778912	0,774464	0,783371	0,775567	0,763892	0,787111	0,784892
	9	0,756106	0,770787	0,767066	0,767882	0,773766	0,771944	0,769458	0,785271	0,770695	0,780545	0,771269	0,769989	0,766828	0,770403	0,774993	0,771648
	10	0,862390	0,862399	0,859884	0,864568	0,858433	0,866245	0,861960	0,862013	0,864960	0,861020	0,862205	0,858652	0,858325	0,860433	0,860564	0,858540
12	1	0,789057	0,787934	0,807433	0,803987	0,807386	0,804219	0,796273	0,820705	0,821118	0,822127	0,799466	0,809531	0,828026	0,808125	0,819349	0,818666
	2	0,784173	0,761960	0,784576	0,781878	0,789227	0,773606	0,769879	0,803153	0,801603	0,803938	0,786819	0,791470	0,786533	0,783160	0,801042	0,787640
	3	0,728727	0,715271	0,722192	0,705187	0,721212	0,717852	0,743614	0,788665	0,789277	0,779534	0,784451	0,783587	0,784623	0,791904	0,799077	0,789111
	4	0,810937	0,809688	0,790803	0,816359	0,798932	0,801554	0,800669	0,843393	0,828397	0,809672	0,816031	0,792819	0,817549	0,805020	0,821148	0,822526
	5	0,771370	0,774510	0,776395	0,775393	0,772788	0,774676	0,771520	0,787024	0,773967	0,776435	0,775644	0,775690	0,774396	0,777278	0,780678	0,775968
	6	0,819017	0,815945	0,813615	0,818192	0,808488	0,823350	0,815513	0,820385	0,813175	0,820076	0,820850	0,818627	0,816357	0,821679	0,816372	0,818960
	7	0,915939	0,912520	0,918848	0,920261	0,919086	0,918225	0,924939	0,919123	0,921444	0,918497	0,918407	0,916669	0,920110	0,918772	0,920769	0,918108
	8	0,797738	0,800491	0,815032	0,806480	0,823526	0,807493	0,807666	0,810541	0,815118	0,816282	0,825541	0,813660	0,807531	0,815664	0,809694	0,817978
	9	0,794817	0,809281	0,795094	0,803743	0,804780	0,807280	0,799185	0,813650	0,791259	0,801269	0,793747	0,798930	0,797578	0,814342	0,799119	0,803994
	10	0,878834	0,874301	0,878936	0,875195	0,874922	0,878556	0,875322	0,877421	0,871141	0,879089	0,873518	0,877144	0,878162	0,875055	0,878324	0,875028

Ek Tablo 11. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların SSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,305073	0,312907	0,301294	0,308138	0,304204	0,311645	0,297885	0,312449	0,319763	0,311506	0,309404	0,309815	0,311836	0,310911	0,315741	0,317835
	2	0,168288	0,179575	0,174076	0,171722	0,170027	0,166550	0,166932	0,179803	0,180643	0,179950	0,172009	0,171190	0,173830	0,169533	0,177698	0,182044
	3	0,210071	0,222046	0,230912	0,218728	0,230222	0,231893	0,224377	0,245295	0,236992	0,245335	0,243198	0,245586	0,230265	0,236116	0,244100	0,241411
	4	0,371689	0,386680	0,384381	0,378524	0,380702	0,384824	0,379751	0,398193	0,405653	0,397477	0,375875	0,394716	0,396174	0,390093	0,389922	0,384867
	5	0,376128	0,372033	0,376738	0,374769	0,376039	0,374734	0,370769	0,383795	0,377978	0,376897	0,375194	0,375151	0,376380	0,373107	0,379057	0,376965
	6	0,584279	0,587407	0,581943	0,576096	0,581668	0,578342	0,589787	0,588096	0,587003	0,588717	0,586231	0,586296	0,584416	0,589093	0,590057	0,589398
	7	0,501002	0,498768	0,501704	0,520303	0,509880	0,511507	0,503502	0,532145	0,531413	0,527500	0,526828	0,518937	0,523991	0,513825	0,526534	0,534019
	8	0,245094	0,238196	0,239595	0,242120	0,243040	0,245116	0,246324	0,243214	0,247828	0,254225	0,252453	0,252700	0,248219	0,252734	0,253058	0,256060
	9	0,309760	0,302540	0,301044	0,269673	0,296143	0,297336	0,288698	0,324531	0,317912	0,335990	0,320860	0,306065	0,299736	0,306541	0,330339	0,319287
	10	0,645633	0,637757	0,644864	0,650214	0,640025	0,637625	0,646594	0,642199	0,645762	0,623645	0,639283	0,633370	0,638125	0,639699	0,625323	0,635977
4	1	0,452744	0,448755	0,476479	0,462566	0,458457	0,470086	0,465528	0,471112	0,467890	0,480539	0,467693	0,460701	0,481239	0,466301	0,462905	0,476568
	2	0,344658	0,338493	0,345169	0,295545	0,311827	0,331196	0,321506	0,360177	0,346704	0,341694	0,329358	0,349228	0,349286	0,321443	0,361497	0,381105
	3	0,348166	0,354305	0,359236	0,361819	0,358595	0,362024	0,363021	0,390005	0,387525	0,379031	0,383554	0,360867	0,370951	0,372656	0,389915	0,369914
	4	0,516417	0,501643	0,510134	0,508228	0,511657	0,502924	0,509546	0,532817	0,529523	0,514016	0,511278	0,519808	0,520892	0,530765	0,528904	0,528473
	5	0,507785	0,509638	0,504210	0,495942	0,489141	0,512458	0,506539	0,522889	0,512690	0,517667	0,516352	0,508474	0,509235	0,489578	0,515547	0,519612
	6	0,688702	0,687670	0,704523	0,697782	0,700411	0,700771	0,696683	0,716577	0,717514	0,712784	0,703162	0,694071	0,700386	0,699851	0,707842	0,708986
	7	0,713208	0,725303	0,719889	0,723210	0,718343	0,707103	0,717053	0,730575	0,732064	0,712522	0,707208	0,720300	0,719316	0,729206	0,715825	0,731709
	8	0,429363	0,406549	0,432591	0,426837	0,418692	0,421531	0,424896	0,436817	0,450136	0,456969	0,415011	0,423754	0,416036	0,420188	0,450785	0,448354
	9	0,484888	0,492685	0,498150	0,514569	0,492066	0,477024	0,493786	0,525935	0,515620	0,501662	0,516134	0,485119	0,498053	0,495839	0,521802	0,515644
	10	0,751738	0,753803	0,754623	0,757042	0,758865	0,759135	0,761302	0,754380	0,750984	0,749834	0,758627	0,764378	0,760072	0,752655	0,757572	0,753133
6	1	0,582286	0,593260	0,596419	0,556719	0,583149	0,584392	0,569879	0,575338	0,597584	0,608954	0,564367	0,571252	0,599770	0,566274	0,584217	0,579022
	2	0,493245	0,518937	0,471284	0,486017	0,472756	0,505953	0,500711	0,510958	0,516654	0,495260	0,499044	0,510571	0,529371	0,485220	0,486477	0,504641
	3	0,446385	0,433305	0,440416	0,448012	0,450047	0,456842	0,447594	0,467109	0,457913	0,475974	0,438353	0,446035	0,449569	0,435376	0,480303	0,451570
	4	0,600893	0,625877	0,639167	0,613540	0,613622	0,610105	0,605232	0,627601	0,625633	0,620640	0,603124	0,609777	0,621725	0,619671	0,630468	0,616836
	5	0,591951	0,570123	0,573384	0,577225	0,578165	0,583704	0,580951	0,580040	0,588278	0,571519	0,578859	0,588480	0,578181	0,578689	0,594626	0,583234
	6	0,744524	0,747909	0,751003	0,738022	0,746915	0,739193	0,745983	0,754890	0,753013	0,749497	0,746881	0,754234	0,749675	0,743733	0,746568	0,748645
	7	0,788475	0,806031	0,809605	0,798806	0,789119	0,806899	0,816211	0,809806	0,806348	0,794286	0,805537	0,800985	0,796110	0,802047	0,810228	0,803999
	8	0,607759	0,612391	0,626776	0,596479	0,558863	0,625134	0,625579	0,625938	0,610956	0,625179	0,618869	0,624255	0,604446	0,574280	0,614437	0,608415
	9	0,618603	0,624534	0,612912	0,611605	0,604027	0,612442	0,612585	0,636223	0,632227	0,626930	0,622843	0,611865	0,615193	0,599304	,	0,619247
	10	0,806926	0,804145	0,806268	0,798900	0,807266	0,791023	0,805126	0,807152	0,804545	0,805473	0,810874	0,801258	0,813149	0,807287	0,809397	0,800174
8	1	0,664390	0,651463	0,640855	0,651029	0,675389	0,659012	0,664413	0,688546	0,669531	0,654861	0,655745	0,667273	0,654749	0,674487	0,660868	0,667054
	2	0,630845	0,610754	0,615055	0,631114	0,619114	0,613370	0,619288	0,583686	0,609814	0,599200	0,610661	0,634123	0,619360	0,624714	0,609951	0,582473

Ek Tablo 11'in devamı

	3	0,513526	0,520544	0,496725	0,510542	0,523453	0,524488	0,513905	0,516893	0,519898	0,529397	0,508782	0,496879	0,508611	0,515898	0,516321	0,515638
	4	0,705417	0,668822	0,683112	0,682139	0,695559	0,709371	0,719214	0,717104	0,694900	0,697004	0,690198	0,699281	0,715208	0,691745	0,703383	0,703838
	5	0,647187	0,639759	0,633604	0,652616	0,632178	0,643005	0,645513	0,650324	0,650939	0,642820	0,639511	0,646256	0,637580	0,642628	0,644386	0,640019
	6	0,771156	0,778925	0,773677	0,774182	0,776237	0,774487	0,782411	0,776487	0,781651	0,780262	0,775364	0,787160	0,778426	0,771879	0,772494	0,777875
	7	0,841447	0,851288	0,861030	0,848314	0,854022	0,861182	0,838421	0,865072	0,859991	0,867030	0,859067	0,850930	0,853020	0,856674	0,862194	0,859214
	8	0,702206	0,688004	0,693367	0,722262	0,726580	0,697683	0,694862	0,696757	0,654026	0,693024	0,681201	0,687406	0,709632	0,698867	0,719304	0,716317
	9	0,683038	0,681705	0,694536	0,693405	0,681007	0,669103	0,677527	0,690349	0,679725	0,700750	0,674036	0,682615	0,695589	0,685056	0,681614	0,711370
	10	0,840039	0,822507	0,834664	0,833260	0,830412	0,829321	0,835852	0,832569	0,828952	0,830133	0,831997	0,840525	0,835847	0,833426	0,833151	0,832584
10	1	0,712696	0,712536	0,717299	0,735071	0,699941	0,708765	0,718295	0,723660	0,724569	0,722461	0,720529	0,727966	0,731983	0,722143	0,696036	0,729228
	2	0,659373	0,681913	0,688149	0,692243	0,687990	0,687823	0,682520	0,697658	0,681980	0,702444	0,686308	0,673195	0,685276	0,700287	0,687610	0,679333
	3	0,581978	0,572144	0,569916	0,540445	0,572209	0,560463	0,553511	0,559187	0,571104	0,564773	0,578889	0,573923	0,546252	0,579771	0,579598	0,580001
	4	0,730343	0,738323	0,750716	0,759686	0,752247	0,745950	0,725198	0,744793	0,762480	0,765354	0,744875	0,747273	0,764408	0,727989	0,760347	0,742055
	5	0,694688	0,693641	0,699810	0,689990	0,691487	0,690438	0,692468	0,697221	0,696727	0,704450	0,694847	0,689886	0,688782	0,679806	0,688492	0,693494
	6	0,801886	0,803409	0,806867	0,796398	0,803927	0,803732	0,803652	0,801167	0,799985	0,799925	0,801492	0,803912	0,798913	0,802090	0,803815	0,803486
	7	0,887081	0,881560	0,884854	0,888664	0,883313	0,885567	0,881100	0,878147	0,885867	0,888839	0,881316	0,884826	0,883043	0,883890	0,882101	0,883546
	8	0,762432	0,755443	0,763498	0,769778	0,764512	0,752375	0,773224	0,765071	0,742357	0,762022	0,752801	0,761093	0,768102	0,758712	0,763067	0,772398
	9	0,727274	0,740287	0,738749	0,729628	0,750483	0,736799	0,748850	0,734484	0,730355	0,743883	0,734838	0,739092	0,740692	0,735894	0,736456	0,725120
	10	0,843248	0,851554	0,848731	0,847861	0,844314	0,854333	0,857501	0,844915	0,856151	0,855374	0,851963	0,852079	0,847551	0,851506	0,848073	0,854634
12	1	0,741394	0,748371	0,750047	0,773397	0,756614	0,778056	0,771660	0,761360	0,764332	0,757512	0,752972	0,768282	0,754732	0,772391	0,754409	0,758045
	2	0,730966	0,734735	0,728644	0,747807	0,751637	0,744470	0,756265	0,737994	0,741747	0,749255	0,751634	0,743879	0,741361	0,724457	0,754598	0,731428
	3	0,621217	0,589546	0,605093	0,606261	0,616521	0,607878	0,589586	0,595430	0,601846	0,623016	0,628255	0,613386	0,590781	0,623034	0,595085	0,612381
	4	0,782808	0,786145	0,796981	0,786840	0,780979	0,788663	0,792051	0,786057	0,795047	0,786564	0,775294	0,780619	0,788318	0,775485	0,779726	0,781728
	5	0,735377	0,724453	0,730534	0,735241	0,723087	0,729141	0,720367	0,734050	0,720914	0,729395	0,727216	0,738455	0,738717	0,721744	0,736350	0,728494
	6	0,819895	0,819950	0,819420	0,818738	0,821922	0,824027	0,820495	0,826287	0,822757	0,824885	0,817588	0,825199	0,820988	0,826097	0,821319	0,814667
	7	0,910863	0,901342	0,893434	0,906463	0,906899	0,896152	0,907067	0,908951	0,899963	0,904228	0,900160	0,899118	0,906470	0,901889	0,900331	0,906869
	8	0,807176	0,790302	0,785170	0,804081	0,804698	0,801598	0,790122	0,810662	0,808212	0,805664	0,797679	0,814928	0,797295	0,795549	0,806246	0,791841
	9	0,763508	0,775656	0,767870	0,751276	0,768925	0,790529	0,792238	0,792173	0,765754	0,764357	0,768740	0,776048	0,781305	0,775912	0,781328	0,793449
	10	0,862831	0,864629	0,870571	0,859856	0,865327	0,865510	0,865470	0,869487	0,861109	0,872645	0,869079	0,868076	0,864861	0,864263	0,864016	0,862429

Ek Tablo 12. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların SSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,300322	0,301649	0,305145	0,303766	0,309629	0,311252	0,302243	0,320270	0,320002	0,318695	0,316500	0,316757	0,314864	0,314704	0,314496	0,320195
	2	0,161427	0,162488	0,167275	0,169169	0,171792	0,168973	0,164050	0,177505	0,186041	0,180627	0,183497	0,175331	0,176496	0,173507	0,174398	0,182987
	3	0,221791	0,223759	0,221686	0,233027	0,231824	0,232077	0,232009	0,248539	0,243332	0,238688	0,241570	0,239673	0,232941	0,234347	0,245945	0,240234
	4	0,385952	0,386621	0,379040	0,380797	0,375002	0,382878	0,379973	0,399667	0,406016	0,403299	0,399792	0,392214	0,390939	0,389713	0,396523	0,399815
	5	0,377439	0,374147	0,377013	0,374000	0,374191	0,373620	0,378660	0,380711	0,376142	0,376898	0,375552	0,377817	0,376524	0,376331	0,378770	0,378754
	6	0,587679	0,579954	0,581797	0,577131	0,584125	0,581154	0,577486	0,590437	0,584798	0,591928	0,585852	0,589854	0,587390	0,586714	0,591835	0,589074
	7	0,503275	0,505853	0,507711	0,513681	0,510075	0,517778	0,509323	0,518374	0,522836	0,532781	0,526534	0,510492	0,530607	0,528071	0,539231	0,520348
	8	0,232889	0,240474	0,240548	0,243371	0,240693	0,239013	0,233522	0,257721	0,250522	0,252061	0,246924	0,246049	0,251801	0,244533	0,248819	0,246187
	9	0,291851	0,281458	0,286622	0,286225	0,290308	0,285289	0,302345	0,319754	0,335214	0,334289	0,338857	0,345897	0,302831	0,307976	0,313958	0,343125
	10	0,618977	0,640924	0,639186	0,651370	0,648268	0,639512	0,641607	0,635211	0,643488	0,639563	0,623578	0,635192	0,646205	0,641124	0,642947	0,637563
4	1	0,472351	0,464776	0,447479	0,453098	0,469025	0,451457	0,457741	0,471866	0,470477	0,486496	0,491407	0,469847	0,448288	0,461730	0,484107	0,490084
	2	0,310756	0,326402	0,341038	0,329511	0,339213	0,319760	0,326320	0,367725	0,385839	0,383130	0,330394	0,361182	0,332957	0,362316	0,366584	0,373627
	3	0,366087	0,363801	0,353839	0,363894	0,352510	0,359224	0,364523	0,389580	0,388029	0,393113	0,382371	0,383547	0,356404	0,364388	0,378516	0,386190
	4	0,504958	0,503093	0,509105	0,519078	0,514038	0,524563	0,496692	0,536897	0,533503	0,548238	0,508819	0,536474	0,519902	0,509386	0,523143	0,503469
	5	0,505790	0,499653	0,514353	0,511112	0,509810	0,510402	0,513202	0,520024	0,516855	0,513194	0,523021	0,521000	0,511451	0,502487	0,522930	0,525561
	6	0,696972	0,701281	0,688201	0,689220	0,699587	0,704784	0,688144	0,714597	0,715731	0,726060	0,706760	0,712811	0,709674	0,700314	0,718913	0,707600
	7	0,712431	0,708922	0,709435	0,722172	0,709614	0,709897	0,727324	0,734993	0,722308	0,714678	0,714164	0,708673	0,719591	0,716967	0,722295	0,725179
	8	0,440946	0,448982	0,416343	0,432659	0,432872	0,422606	0,424532	0,452969	0,472966	0,462756	0,452809	0,433485	0,433378	0,439336	0,427168	0,437117
	9	0,512257	0,491412	0,487493	0,493860	0,493900	0,492726	0,509754	0,524795	0,520974	0,513241	0,523030	0,502777	0,532984	0,481788	0,518725	0,519087
	10	0,761172	0,754526	0,752282	0,765461	0,770149	0,767983	0,763335	0,752234	0,749079	0,752544	0,749550	0,751166	0,751998	0,763481	0,756289	0,763419
6	1	0,589222	0,567183	0,585492	0,569631	0,579975	0,594534	0,577380	0,577840	0,595235	0,580481	0,578880	0,593965	0,588275	0,567629	0,577619	0,590889
	2	0,504245	0,529292	0,486927	0,504456	0,502723	0,467404	0,503527	0,545729	0,537009	0,508030	0,534324	0,509942	0,517993	0,519062	0,540842	0,526998
	3	0,454538	0,443569	0,452392	0,450422	0,422272	0,448762	0,433568	0,455585	0,472353	0,472478	0,459435	0,447985	0,453569	0,445631	0,455798	0,450843
	4	0,625968	0,608293	0,613671	0,620650	0,615737	0,626716	0,616606	0,630728	0,648845	0,635111	0,628092	0,619450	0,605430	0,595796	0,647511	0,631407
	5	0,570938	0,575291	0,585822	0,576146	0,580383	0,570844	0,574773	0,583670	0,593509	0,573491	0,581248	0,573056	0,575362	0,576202	0,595916	0,581653
	6	0,746173	0,737152	0,743861	0,750348	0,745393	0,744777	0,737705	0,754708	0,756715	0,749121	0,752073	0,744639	0,741916	0,743796	0,753054	0,756803
	7	0,807244	0,801899	0,805060	0,805497	0,801468	0,805030	0,805382	0,814460	0,797973	0,809676	0,793381	0,806964	0,810433	0,811817	0,807622	0,803568
	8	0,610355	0,606707	0,617531	0,603936	0,570201	0,594204	0,586312	0,622344	0,594502	0,606290	0,585538	0,608174	0,601999	0,614306	0,638923	0,620336
	9	0,589316	0,617287	0,594773	0,609586	0,617101	0,618841	0,612617	0,639750	0,620817	0,622735	0,613248	0,610349	0,592972	0,618928	0,623329	0,615397
	10	0,799505	0,799454	0,806226	0,803815	0,814314	0,800748	0,797669	0,803355	0,798967	0,801586	0,803203	0,799706	0,801327	0,799589	0,808658	0,798614
8	1	0,660300	0,659233	0,651346	0,658177	0,679056	0,656207	0,661392	0,664475	0,686099	0,651858	0,644853	0,679258	0,656733	0,654827	0,668596	0,656083
	2	0,636374	0,610524	0,613150	0,619007	0,599154	0,611552	0,613683	0,617318	0,639836	0,639389	0,614644	0,608805	0,619614	0,628964	0,593375	0,615950

Ek Tablo 12'in devamı

	3	0,518316	0,510325	0,493606	0,517706	0,496174	0,517156	0,489115	0,539137	0,525648	0,510288	0,505257	0,518514	0,519557	0,511647	0,513198	0,526255
	4	0,692293	0,672146	0,704312	0,697056	0,677578	0,681187	0,692564	0,685940	0,718227	0,698110	0,706926	0,700598	0,691180	0,681202	0,695917	0,711317
	5	0,641369	0,631049	0,652319	0,641139	0,643611	0,643573	0,638319	0,645538	0,647855	0,640175	0,641853	0,645629	0,642532	0,630553	0,644908	0,626154
	6	0,779149	0,768500	0,783119	0,779777	0,780227	0,776589	0,774831	0,778376	0,779174	0,776547	0,784183	0,773968	0,779437	0,782988	0,784363	0,783843
	7	0,848362	0,845547	0,854113	0,851375	0,855763	0,853918	0,858374	0,859352	0,855807	0,851238	0,854705	0,860841	0,853186	0,849006	0,851767	0,856947
	8	0,693158	0,686496	0,697909	0,699638	0,699877	0,693379	0,695560	0,720464	0,724413	0,694792	0,696080	0,678366	0,693241	0,673876	0,695733	0,713826
	9	0,668288	0,684302	0,672719	0,681458	0,692644	0,673395	0,671116	0,685755	0,699279	0,688631	0,693867	0,691687	0,701697	0,666554	0,688799	0,677418
	10	0,838680	0,829086	0,830638	0,830947	0,835369	0,836829	0,823471	0,820731	0,829346	0,832784	0,841351	0,827832	0,823167	0,832421	0,827002	0,825050
10	1	0,719484	0,698147	0,711413	0,706622	0,709096	0,723221	0,723462	0,723394	0,704340	0,729392	0,721123	0,725268	0,709184	0,702256	0,697821	0,728558
	2	0,695154	0,668469	0,677334	0,652511	0,686514	0,678786	0,643694	0,707345	0,696747	0,695393	0,684516	0,665255	0,687297	0,697901	0,700733	0,693919
	3	0,581352	0,581389	0,583196	0,563194	0,580150	0,553531	0,551915	0,569221	0,576903	0,571698	0,570000	0,564614	0,573533	0,591695	0,592929	0,584158
	4	0,751656	0,726683	0,744853	0,733139	0,751572	0,762235	0,741418	0,762641	0,747132	0,751983	0,762257	0,727366	0,733146	0,758465	0,759847	0,739820
	5	0,692148	0,703604	0,695992	0,693447	0,699307	0,690626	0,696689	0,694839	0,689587	0,702272	0,693104	0,703967	0,685449	0,694154	0,694832	0,695914
	6	0,796707	0,802322	0,804461	0,805582	0,802154	0,804346	0,797555	0,804724	0,803531	0,803557	0,802667	0,809034	0,798988	0,806818	0,799095	0,800385
	7	0,876715	0,882403	0,887678	0,879381	0,883946	0,874824	0,889538	0,883698	0,882457	0,883971	0,886064	0,881529	0,873967	0,887006	0,886957	0,887830
	8	0,744514	0,757943	0,766835	0,772402	0,762885	0,775914	0,752177	0,749944	0,742977	0,775667	0,764389	0,741737	0,748730	0,756578	0,744583	0,762323
	9	0,738555	0,752168	0,725053	0,729171	0,729031	0,731496	0,743349	0,742013	0,742172	0,736068	0,720842	0,739461	0,736807	0,719440	0,723632	0,724516
	10	0,855453	0,851817	0,854485	0,851801	0,850890	0,856567	0,852686	0,842720	0,842791	0,855129	0,855170	0,846171	0,851949	0,851585	0,851857	0,850558
12	1	0,755906	0,755986	0,764844	0,778507	0,760819	0,772329	0,746389	0,758899	0,753863	0,740399	0,766767	0,774949	0,766231	0,761183	0,771549	0,764064
	2	0,726160	0,734459	0,734310	0,709658	0,713717	0,743070	0,721704	0,759136	0,738227	0,732471	0,735737	0,733024	0,721820	0,736978	0,732486	0,735428
	3	0,600395	0,607704	0,615197	0,609340	0,621868	0,628113	0,602070	0,619502	0,609257	0,590811	0,643697	0,616221	0,596518	0,593672	0,632106	0,619184
	4	0,787558	0,782470	0,787366	0,772988	0,799322	0,789108	0,778454	0,780533	0,767333	0,784873	0,785367	0,777727	0,783469	0,784810	0,792418	0,780493
	5	0,727256	0,728299	0,728793	0,732380	0,731390	0,732488	0,740390	0,731440	0,721278	0,729703	0,723258	0,737370	0,739759	0,731883	0,727567	0,731741
	6	0,824126	0,820026	0,821891	0,817554	0,820273	0,827103	0,824673	0,821338	0,821251	0,816669	0,819034	0,829934	0,820135	0,821245	0,821449	0,822375
	7	0,902066	0,906123	0,902949	0,901823	0,906224	0,900227	0,909534	0,912473	0,897609	0,907013	0,902564	0,899446	0,906751	0,903198	0,909332	0,908920
	8	0,801324	0,796312	0,798793	0,804036	0,804074	0,798059	0,791041	0,792840	0,802558	0,804016	0,794803	0,810319	0,775934	0,791189	0,803179	0,800668
	9	0,756655	0,768945	0,781707	0,784040	0,774523	0,787611	0,790148	0,790613	0,764266	0,781597	0,784436	0,792164	0,773554	0,778802	0,779967	0,773104
	10	0,867470	0,869849	0,866625	0,865905	0,868063	0,867135	0,864187	0,865874	0,869486	0,867677	0,865118	0,866498	0,870757	0,860018	0,855255	0,861974

Otsu Yöntemi:

- Ek Tablo 13 ($maxFEs = 500 \times m$): WChOA ve WChOA-UMD yöntemleri, 60 deneyin 54'ünde en yüksek FSIM değerlerini elde etmiştir.
- EK Tablo 14 ($maxFEs = 1000 \times m$): En yüksek FSIM değerleri 60 deneyin 51'inde kaydedilmiştir.

Kapur Entropisi:

- EK Tablo 15 ($maxFEs = 500 \times m$): Önerilen yöntemler, 60 deneyin 48'inde rakiplerini geride bırakmıştır.
- EK Tablo 16 ($maxFEs = 1000 \times m$): Başarılı deney sayısı 60 deneyin 48'inde kalmıştır.

Ek Tablo 13. Otsu yöntemi ve $maxFEs=500 \times m$ algoritmaların FSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,620293	0,618579	0,625389	0,622464	0,620051	0,622360	0,623761	0,631512	0,630091	0,632238	0,630280	0,629710	0,626848	0,628939	0,630382	0,631609
	2	0,655678	0,655902	0,661142	0,657751	0,658228	0,656870	0,660698	0,671682	0,670454	0,672319	0,665925	0,668407	0,667793	0,661646	0,669003	0,670290
	3	0,682203	0,682650	0,682523	0,682274	0,685430	0,682326	0,683809	0,693706	0,694960	0,691825	0,690065	0,691713	0,693986	0,689688	0,694501	0,693497
	4	0,694770	0,690458	0,696850	0,698686	0,693662	0,695323	0,696330	0,717741	0,717650	0,717919	0,714776	0,715363	0,710610	0,710227	0,717914	0,718028
	5	0,713026	0,712874	0,715124	0,715228	0,714435	0,715519	0,713957	0,716256	0,715687	0,716701	0,717186	0,714513	0,715066	0,715474	0,716520	0,712980
	6	0,685205	0,682301	0,682697	0,684802	0,681623	0,682251	0,682243	0,684627	0,685081	0,684350	0,685077	0,686949	0,683385	0,685006	0,686938	0,683159
	7	0,719502	0,715422	0,719862	0,721142	0,721208	0,716769	0,719360	0,720966	0,722163	0,722242	0,723000	0,720650	0,722671	0,718921	0,721265	0,721250
	8	0,657701	0,651779	0,657017	0,659115	0,658244	0,661289	0,659582	0,660596	0,664628	0,657849	0,664734	0,665956	0,661445	0,664824	0,663190	0,664166
	9	0,676781	0,677305	0,680879	0,681961	0,679821	0,676769	0,678753	0,685256	0,687313	0,687547	0,682875	0,686125	0,688520	0,682600	0,683652	0,688321
	10	0,712433	0,702863	0,713415	0,712532	0,708206	0,711996	0,712241	0,715576	0,714098	0,715256	0,710907	0,712427	0,715755	0,715950	0,715505	0,712828
4	1	0,723093	0,736390	0,728762	0,730858	0,730740	0,730011	0,731171	0,737818	0,739187	0,743916	0,733906	0,738631	0,736648	0,741057	0,739697	0,738839
	2	0,749127	0,750555	0,750633	0,748038	0,748632	0,745082	0,749164	0,759717	0,761771	0,758967	0,751845	0,755694	0,758665	0,751266	0,756640	0,759288
	3	0,748504	0,748243	0,752552	0,745070	0,752162	0,751765	0,750316	0,766083	0,762842	0,764532	0,759879	0,760244	0,759169	0,758844	0,763663	0,763826
	4	0,776859	0,777914	0,785058	0,787214	0,782330	0,786166	0,787129	0,798347	0,792457	0,796331	0,791746	0,786135	0,796062	0,788666	0,794386	0,793725
	5	0,779773	0,781483	0,781828	0,783253	0,782203	0,783247	0,782179	0,784035	0,782115	0,784080	0,784068	0,782902	0,781016	0,781825	0,782069	0,782738
	6	0,711526	0,708296	0,711473	0,709544	0,710448	0,707940	0,708673	0,712455	0,710440	0,708062	0,707114	0,707166	0,708672	0,707103	0,709589	0,705019
	7	0,816924	0,819254	0,820129	0,821644	0,822923	0,825513	0,819444	0,820789	0,820803	0,820073	0,821512	0,821775	0,821968	0,826915	0,825454	0,826163
	8	0,742393	0,753054	0,754189	0,748860	0,751310	0,750215	0,751524	0,757709	0,751189	0,762766	0,753039	0,753118	0,759428	0,745831	0,762610	0,756205

Ek Tablo 13'ün devamı

	9	0,778573	0,773724	0,780612	0,779794	0,773323	0,772901	0,775924	0,784931	0,783263	0,787858	0,786136	0,779294	0,778041	0,775280	0,788316	0,786357
	10	0,788149	0,791454	0,793219	0,791824	0,794651	0,794127	0,797246	0,794928	0,796541	0,792575	0,790794	0,793169	0,796444	0,791050	0,793934	0,801087
6	1	0,790555	0,795448	0,793984	0,791732	0,791558	0,789508	0,788297	0,800838	0,798625	0,798679	0,795400	0,797170	0,799658	0,795017	0,798109	0,799263
	2	0,801264	0,800122	0,800797	0,804297	0,804406	0,803536	0,803240	0,811251	0,812606	0,810854	0,814077	0,813907	0,809052	0,803858	0,811353	0,809858
	3	0,791500	0,792480	0,792342	0,793784	0,796831	0,794934	0,795182	0,806128	0,802486	0,807375	0,805612	0,806210	0,804029	0,807000	0,807887	0,806694
	4	0,829435	0,830766	0,833007	0,831048	0,828565	0,828504	0,830218	0,839654	0,837624	0,836041	0,833711	0,837370	0,834270	0,831994	0,838825	0,839185
	5	0,822386	0,820034	0,819101	0,821992	0,821659	0,820946	0,821767	0,824499	0,825029	0,824021	0,821889	0,821879	0,825444	0,823057	0,829749	0,823480
	6	0,741258	0,741353	0,740815	0,741212	0,737144	0,742517	0,741746	0,743487	0,738707	0,740427	0,740185	0,736874	0,738982	0,743342	0,738248	0,745657
	7	0,875163	0,866636	0,874087	0,869634	0,872554	0,876846	0,869601	0,876063	0,872872	0,872148	0,871012	0,874352	0,878811	0,872656	0,866338	0,872396
	8	0,797629	0,808741	0,818160	0,812164	0,813008	0,814204	0,808357	0,820299	0,811912	0,813521	0,814808	0,812856	0,813384	0,812926	0,811621	0,818035
	9	0,819646	0,826226	0,823385	0,827426	0,826913	0,823073	0,823229	0,831055	0,832751	0,830475	0,825220	0,827944	0,829302	0,825919	0,830790	0,829868
	10	0,831550	0,827600	0,831400	0,832158	0,829445	0,830433	0,834168	0,827977	0,833362	0,837737	0,832217	0,829806	0,831675	0,831304	0,831242	0,828505
8	1	0,827020	0,828524	0,835492	0,833687	0,836743	0,831070	0,833934	0,837460	0,841657	0,838625	0,834398	0,834484	0,836735	0,835964	0,838403	0,834162
	2	0,835373	0,838860	0,840078	0,834018	0,840979	0,842001	0,835438	0,847500	0,851778	0,849576	0,844402	0,845885	0,843446	0,847715	0,851962	0,848512
	3	0,820628	0,825224	0,828739	0,826756	0,827906	0,829806	0,828201	0,838616	0,835168	0,837242	0,834126	0,836603	0,833306	0,835573	0,835226	0,837315
	4	0,856191	0,861256	0,857872	0,861769	0,858308	0,866770	0,861362	0,870469	0,868745	0,870143	0,866672	0,863404	0,866476	0,861533	0,865806	0,866314
	5	0,852380	0,849683	0,855147	0,850913	0,853956	0,852307	0,855300	0,851010	0,854674	0,854370	0,855116	0,854813	0,851354	0,854903	0,858198	0,852812
	6	0,772559	0,765614	0,767514	0,767377	0,771498	0,769465	0,767228	0,771493	0,770766	0,769202	0,768344	0,769025	0,773644	0,771784	0,769433	0,767966
	7	0,905117	0,904056	0,904140	0,896540	0,899702	0,903862	0,905890	0,905691	0,900430	0,904134	0,900599	0,899921	0,904868	0,900383	0,902522	0,899447
	8	0,846864	0,846940	0,848454	0,848841	0,843217	0,850470	0,846734	0,852976	0,862157	0,855940	0,851060	0,859364	0,849163	0,852729	0,851758	0,853174
	9	0,851947	0,852881	0,856101	0,856999	0,852179	0,855322	0,856317	0,855076	0,856404	0,857792	0,857867	0,855570	0,855905	0,853525	0,856385	0,857878
	10	0,852304	0,856624	0,858004	0,852375	0,860822	0,853701	0,857350	0,856236	0,857175	0,856197	0,858000	0,859909	0,856746	0,858230	0,857491	0,857756
10	1	0,859872	0,859206	0,863994	0,860118	0,861902	0,863395	0,860917	0,866969	0,864492	0,866680	0,860638	0,865463	0,864622	0,862908	0,868007	0,868616
	2	0,874410	0,862837	0,869054	0,872621	0,871234	0,866645	0,870158	0,874269	0,871430	0,877694	0,870392	0,874255	0,868127	0,874104	0,875614	0,873352
	3	0,850097	0,846994	0,851793	0,852573	0,851734	0,855014	0,850275	0,861058	0,862420	0,863001	0,856589	0,859785	0,861265	0,857624	0,859995	0,860522
	4	0,880656	0,884631	0,886041	0,883335	0,885462	0,882965	0,886138	0,890773	0,887668	0,889129	0,884210	0,887394	0,882761	0,884778	0,889826	0,887599
	5	0,874972	0,874107	0,874105	0,876992	0,876035	0,874034	0,873218	0,878411	0,875466	0,874845	0,876678	0,876972	0,874926	0,876207	0,878486	0,876006
	6	0,790475	0,796887	0,793425	0,792065	0,791249	0,791148	0,794583	0,792155	0,795710	0,793507	0,790871	0,794657	0,794461	0,790541	0,794223	0,792719
	7	0,922537	0,921169	0,924415	0,924201	0,922981	0,923810	0,923285	0,921079	0,915674	0,921076	0,921278	0,923082	0,919571	0,920986	0,921316	0,922953
	8	0,881688	0,877348	0,875957	0,873375	0,878351	0,881471	0,873068	0,893209	0,881794	0,879047	0,877127	0,872523	0,889641	0,881366	0,883190	0,888826
	9	0,873854	0,874077	0,874723	0,878568	0,877438	0,875048	0,876722	0,875440	0,875575	0,877032	0,875497	0,874738	0,875888	0,873842	0,876853	0,876309
	10	0,876301	0,876112	0,877327	0,879066	0,874955	0,879076	0,877478	0,877484	0,878100	0,879737	0,879349	0,875318	0,881482	0,875849	0,876625	0,881580
12	1	0,882356	0,886557	0,883376	0,883204	0,888202	0,886417	0,885079	0,889056	0,889919	0,885127	0,882077	0,886073	0,887696	0,886502	0,888622	0,888207
	2	0,888979	0,890254	0,882426	0,888772	0,887488	0,889053	0,890166	0,895279	0,897781	0,900327	0,889328	0,895610	0,895143	0,892925	0,896731	0,892834
	3	0,867158	0,869966	0,869958	0,871699	0,871837	0,872206	0,873569	0,879789	0,877908	0,880569	0,877806	0,876342	0,876710	0,875364	0,878980	0,877543
	4	0,896990	0,896698	0,902447	0,901375	0,894325	0,902029	0,900771	0,905983	0,904395	0,903324	0,897210	0,899905	0,900679	0,900196	0,904941	0,902883
	5	0,889936	0,891896	0,894208	0,896279	0,890498	0,896689	0,893995	0,893031	0,895397	0,894434	0,891616	0,892724	0,893590	0,894897	0,893946	0,893378

6	0,809970	0,811556	0,814476	0,814326	0,814428	0,814785	0,813790	0,814329	0,813867	0,814612	0,814260	0,814065	0,812146	0,813824	0,812370	0,815636
7	0,936765	0,935793	0,937949	0,938425	0,938041	0,936985	0,936529	0,931502	0,938603	0,939261	0,938222	0,935742	0,938868	0,939811	0,935720	0,939847
8	0,893752	0,910259	0,901762	0,901224	0,895456	0,902593	0,902652	0,912214	0,904516	0,904559	0,906533	0,907711	0,898892	0,897479	0,900235	0,907246
9	0,891523	0,889472	0,890390	0,893969	0,894021	0,891871	0,893124	0,893323	0,890729	0,892911	0,893963	0,891473	0,892059	0,894447	0,893724	0,892669
10	0,891222	0,892279	0,891632	0,896441	0,890954	0,891770	0,895261	0,897983	0,893406	0,890784	0,894229	0,896927	0,893102	0,893274	0,893804	0,893076

Ek Tablo 14. Otsu yöntemi ve $maxFEs=1000 \times m$ algoritmaların FSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,619379	0,623517	0,623929	0,625239	0,621680	0,622441	0,627321	0,632296	0,634583	0,630682	0,631557	0,627337	0,631311	0,629844	0,631342	0,632170
	2	0,657335	0,657419	0,663091	0,652746	0,659533	0,659524	0,656466	0,672529	0,670021	0,670465	0,669956	0,671015	0,667377	0,666895	0,671851	0,670885
	3	0,683436	0,683843	0,684079	0,685104	0,684854	0,684118	0,683060	0,696948	0,694068	0,696180	0,692971	0,692337	0,692773	0,690724	0,693100	0,694416
	4	0,693727	0,690582	0,686514	0,705627	0,698272	0,698598	0,695775	0,718594	0,717996	0,715355	0,712427	0,717220	0,714108	0,711951	0,717665	0,720546
	5	0,711931	0,713794	0,713274	0,713944	0,715796	0,715806	0,715889	0,716243	0,715069	0,716379	0,715028	0,714770	0,714914	0,715087	0,715151	0,716195
	6	0,685966	0,683632	0,682504	0,686232	0,681428	0,684382	0,682181	0,686352	0,685411	0,685707	0,682476	0,688412	0,684840	0,684361	0,689154	0,686392
	7	0,717534	0,713591	0,719791	0,716636	0,721707	0,722146	0,719395	0,724985	0,722861	0,723995	0,724046	0,721265	0,721486	0,718951	0,720612	0,725412
	8	0,655088	0,657763	0,662703	0,663528	0,661406	0,657650	0,659947	0,661422	0,658511	0,664344	0,660705	0,660613	0,665130	0,659404	0,662474	0,663158
	9	0,677597	0,678633	0,679862	0,678344	0,674236	0,684346	0,674345	0,688069	0,688952	0,686728	0,684425	0,686195	0,687161	0,680902	0,688879	0,685222
	10	0,707588	0,710868	0,710689	0,716640	0,713683	0,714064	0,714699	0,713790	0,712599	0,713797	0,710304	0,719846	0,714365	0,720738	0,716160	0,714108
4	1	0,725482	0,725481	0,730227	0,735247	0,733242	0,732778	0,727369	0,741977	0,746482	0,741264	0,739187	0,737438	0,735662	0,740935	0,741245	0,741299
	2	0,745010	0,743172	0,746340	0,747458	0,745458	0,746117	0,751205	0,763080	0,762261	0,761452	0,752354	0,756662	0,752500	0,754611	0,755989	0,761645
	3	0,747102	0,746272	0,754641	0,747202	0,748345	0,750973	0,748808	0,764267	0,764970	0,762114	0,762567	0,761057	0,761735	0,758311	0,760323	0,763764
	4	0,787126	0,779813	0,782776	0,780520	0,783567	0,787578	0,786756	0,801518	0,798050	0,802372	0,790442	0,795264	0,790881	0,792936	0,796965	0,799391
	5	0,778712	0,781028	0,779756	0,780029	0,783627	0,781589	0,778866	0,785029	0,784266	0,784127	0,785396	0,784689	0,782076	0,783716	0,778955	0,784194
	6	0,710147	0,708154	0,710595	0,707472	0,709259	0,707523	0,705986	0,708743	0,709399	0,707228	0,707170	0,709646	0,709177	0,710015	0,708800	0,710620
	7	0,818025	0,821686	0,825956	0,821591	0,826160	0,823238	0,825733	0,826018	0,825880	0,829635	0,822522	0,830219	0,825150	0,825175	0,821058	0,828481
	8	0,750787	0,742410	0,747155	0,750236	0,750500	0,753221	0,753455	0,755836	0,752659	0,758431	0,756635	0,758731	0,752061	0,757729	0,764426	0,758153
	9	0,774621	0,776492	0,778408	0,780080	0,776718	0,772590	0,773008	0,789904	0,787034	0,786375	0,784609	0,781100	0,782949	0,781657	0,789491	0,788607
	10	0,796843	0,797036	0,798072	0,795542	0,795245	0,794957	0,795579	0,798085	0,792247	0,798210	0,793732	0,792320	0,796369	0,791785	0,792140	0,798572
6	1	0,787190	0,789797	0,795494	0,788900	0,795626	0,791195	0,788844	0,799513	0,798240	0,796011	0,799434	0,798186	0,798215	0,794670	0,797644	0,797919
	2	0,797409	0,804074	0,799405	0,804174	0,802684	0,798913	0,801291	0,816893	0,811702	0,815781	0,809425	0,809063	0,805136	0,806490	0,815209	0,810349
	3	0,791278	0,793483	0,791514	0,795616	0,795081	0,795879	0,791920	0,807841	0,806741	0,812607	0,806021	0,803597	0,806138	0,802848	0,806249	0,808342
	4	0,828994	0,830524	0,833199	0,836419	0,829373	0,829090	0,824820	0,841748	0,840876	0,837966	0,834086	0,841067	0,836728	0,833411	0,838928	0,839724
	5	0,816294	0,818782	0,826253	0,820481	0,822639	0,824080	0,823223	0,824534	0,822786	0,827471	0,825912	0,824698	0,820108	0,819387	0,825181	0,826131
	6	0,740109	0,740107	0,741311	0,739136	0,739001	0,740958	0,739123	0,739802	0,740667	0,736942	0,738093	0,738997	0,738215	0,738168	0,742322	0,739643
	7	0,866422	0,873310	0,873168	0,870090	0,868256	0,868537	0,869031	0,873724	0,871647	0,869231	0,872878	0,868229	0,871348	0,868391	0,873524	0,874244
	8	0,807822	0,812231	0,802481	0,813950	0,810658	0,806389	0,803904	0,821933	0,814255	0,819239	0,816396	0,810681	0,807118	0,803521	0,821644	0,817682
	9	0,824248	0,819111	0,821418	0,825753	0,826992	0,822339	0,826236	0,831870	0,832170	0,828691	0,828137	0,826320	0,828331	0,826928	0,832684	0,829582
	10	0,833885	0,833045	0,832898	0,833030	0,835399	0,838580	0,831702	0,830691	0,829472	0,832545	0,833169	0,833020	0,832665	0,832308	0,837072	0,824796
8	1	0,828867	0,833084	0,827774	0,830133	0,835213	0,832784	0,830619	0,837064	0,838321	0,839321	0,835769	0,837585	0,836740	0,832904	0,837492	0,838072
	2	0,839393	0,838849	0,841585	0,838092	0,835969	0,842994	0,838248	0,854901	0,856716	0,848838	0,846693	0,845247	0,849405	0,847125	0,850730	0,842988

Ek Tablo 14'ün devamı

	3	0,824220	0,827381	0,831071	0,829484	0,827228	0,829403	0,826788	0,838146	0,837824	0,838517	0,835489	0,839386	0,832447	0,835113	0,839613	0,837464
	4	0,857974	0,860487	0,863751	0,858452	0,865144	0,858560	0,854896	0,871021	0,869447	0,866203	0,861833	0,867751	0,865126	0,860539	0,867796	0,868061
	5	0,852589	0,851850	0,855299	0,850421	0,856758	0,852218	0,855266	0,854184	0,856241	0,851335	0,853794	0,852730	0,852041	0,853962	0,855182	0,854523
	6	0,765245	0,767842	0,769397	0,768541	0,770111	0,770597	0,770075	0,771063	0,769615	0,772641	0,770187	0,770942	0,767024	0,773006	0,770576	0,768037
	7	0,900375	0,898564	0,904905	0,906977	0,903877	0,907244	0,904238	0,903566	0,899222	0,906825	0,897997	0,901675	0,896430	0,898046	0,904366	0,899350
	8	0,836315	0,844257	0,852808	0,847826	0,855985	0,850019	0,847817	0,862468	0,852874	0,855354	0,846288	0,851364	0,842316	0,846751	0,851049	0,859319
	9	0,849112	0,852216	0,853893	0,854114	0,856562	0,852043	0,849918	0,857605	0,856481	0,858250	0,854820	0,854322	0,854514	0,853070	0,855290	0,857897
	10	0,857969	0,854183	0,860373	0,855066	0,860112	0,856703	0,854317	0,860481	0,854611	0,860109	0,854566	0,854824	0,856035	0,860576	0,853819	0,859132
10	1	0,858865	0,858626	0,858989	0,864013	0,860492	0,862744	0,860427	0,864650	0,866671	0,868391	0,862798	0,866153	0,864620	0,864505	0,863621	0,864853
	2	0,865467	0,856745	0,866029	0,863628	0,873068	0,866379	0,869656	0,878171	0,870127	0,879568	0,872294	0,873185	0,869893	0,867191	0,874833	0,873010
	3	0,850409	0,852168	0,851079	0,850720	0,852166	0,850990	0,850810	0,863597	0,862978	0,863235	0,859360	0,859178	0,862287	0,857101	0,860881	0,862330
	4	0,884051	0,884398	0,883732	0,878823	0,884308	0,884492	0,882607	0,891581	0,890070	0,891593	0,885922	0,885809	0,887710	0,882847	0,890123	0,885377
	5	0,874684	0,872658	0,875914	0,878998	0,874914	0,874842	0,875741	0,874369	0,874017	0,874385	0,873389	0,876785	0,873258	0,875587	0,874967	0,872748
	6	0,792353	0,794279	0,793541	0,793270	0,792904	0,792258	0,791645	0,792177	0,793394	0,795726	0,795760	0,792854	0,789257	0,789827	0,795945	0,795831
	7	0,923584	0,923643	0,918851	0,923350	0,924947	0,925576	0,921527	0,924853	0,921968	0,925140	0,916969	0,926240	0,924335	0,919152	0,922860	0,924714
	8	0,870092	0,872645	0,882178	0,877264	0,883443	0,880402	0,875651	0,886193	0,883273	0,882538	0,880751	0,882461	0,877978	0,879103	0,887028	0,881933
	9	0,871580	0,874913	0,876137	0,877069	0,875324	0,875104	0,877058	0,878794	0,874809	0,878605	0,878836	0,875703	0,874452	0,876546	0,876666	0,875812
	10	0,877803	0,879149	0,875843	0,878591	0,876829	0,881115	0,878707	0,880283	0,879606	0,877254	0,880141	0,875237	0,875194	0,876965	0,874881	0,874945
12	1	0,877540	0,879092	0,884416	0,886251	0,889511	0,884052	0,882499	0,887487	0,885162	0,887045	0,882098	0,884084	0,887068	0,884919	0,887502	0,887278
	2	0,891328	0,883623	0,891164	0,891144	0,893726	0,885728	0,888241	0,897500	0,897073	0,896429	0,893590	0,896233	0,893725	0,891531	0,896693	0,894131
	3	0,868079	0,869215	0,871828	0,868049	0,871815	0,871317	0,875051	0,879319	0,878164	0,880642	0,876251	0,878472	0,876661	0,880597	0,880720	0,881233
	4	0,898020	0,898552	0,894762	0,902753	0,898539	0,897249	0,900715	0,909701	0,906248	0,900791	0,901413	0,897323	0,902123	0,899823	0,900635	0,906212
	5	0,889996	0,890034	0,894850	0,895258	0,893206	0,893620	0,892959	0,894125	0,893554	0,893660	0,894029	0,895021	0,894413	0,894210	0,895258	0,893663
	6	0,815453	0,811313	0,813315	0,814577	0,810501	0,817412	0,812088	0,815064	0,812470	0,814553	0,816460	0,814813	0,812267	0,817726	0,813287	0,815457
	7	0,936170	0,932960	0,937885	0,938675	0,937414	0,936856	0,941487	0,936699	0,937879	0,934947	0,936031	0,933848	0,936929	0,936118	0,937292	0,934069
	8	0,895981	0,896438	0,902472	0,899504	0,905452	0,898485	0,898001	0,901947	0,902517	0,903249	0,906024	0,901713	0,901937	0,903412	0,900150	0,902010
	9	0,888636	0,894301	0,892410	0,891947	0,894051	0,894341	0,891492	0,895238	0,890748	0,892739	0,889063	0,891888	0,890374	0,894340	0,890935	0,892203
	10	0,893235	0,892693	0,896279	0,892652	0,893808	0,894945	0,893564	0,894095	0,890442	0,896001	0,893978	0,893945	0,895103	0,892167	0,895026	0,892219

Ek Tablo 15. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların FSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,600696	0,605250	0,599035	0,603625	0,603040	0,606495	0,598932	0,609022	0,610234	0,608606	0,605579	0,606853	0,608347	0,606851	0,609862	0,608588
	2	0,609640	0,615055	0,618999	0,612441	0,612511	0,613500	0,612205	0,620326	0,622094	0,623025	0,613987	0,613155	0,616748	0,615392	0,619998	0,622864
	3	0,638360	0,644127	0,649959	0,641660	0,646052	0,649157	0,643724	0,652080	0,649689	0,652051	0,652344	0,652541	0,647812	0,648340	0,652498	0,650145
	4	0,651114	0,662493	0,658235	0,656371	0,659828	0,657214	0,660933	0,670726	0,676285	0,674607	0,659454	0,664890	0,673061	0,658853	0,671457	0,666216
	5	0,716320	0,717457	0,719288	0,718286	0,718238	0,718613	0,716006	0,718705	0,718584	0,717422	0,717695	0,717258	0,717902	0,718583	0,718305	0,718009
	6	0,699362	0,699622	0,699824	0,696622	0,697903	0,698522	0,701264	0,700257	0,701369	0,700217	0,700595	0,702971	0,699731	0,700247	0,702155	0,701589
	7	0,704311	0,702390	0,702162	0,714878	0,711718	0,709545	0,706979	0,715645	0,715507	0,711874	0,713649	0,713866	0,714807	0,712078	0,713921	0,718669
	8	0,602576	0,598841	0,602028	0,600245	0,604075	0,604606	0,606153	0,605547	0,608339	0,614819	0,609679	0,611797	0,607816	0,611948	0,613332	0,615469
	9	0,647702	0,644498	0,645245	0,632646	0,642147	0,643468	0,641811	0,655164	0,652507	0,660222	0,653108	0,647889	0,645851	0,647461	0,657249	0,652978
	10	0,645654	0,641572	0,644288	0,649020	0,638736	0,641842	0,644770	0,637465	0,644819	0,624399	0,638171	0,634858	0,632698	0,641673	0,625665	0,633002
4	1	0,700698	0,697320	0,710396	0,699819	0,706078	0,701679	0,706987	0,709081	0,705954	0,713814	0,707952	0,707129	0,712516	0,705794	0,710016	0,709086
	2	0,693856	0,694824	0,699592	0,683940	0,693271	0,692310	0,691233	0,703865	0,699616	0,699982	0,691459	0,707632	0,700763	0,698415	0,708791	0,711235
	3	0,710316	0,714417	0,715243	0,716986	0,717522	0,718749	0,715707	0,732580	0,732427	0,726368	0,724798	0,719284	0,720528	0,724051	0,727596	0,723286
	4	0,741941	0,736103	0,745182	0,735287	0,743126	0,739462	0,743845	0,752997	0,752227	0,742570	0,739561	0,743645	0,745595	0,745027	0,750598	0,748023
	5	0,777843	0,776122	0,774676	0,772990	0,772823	0,777295	0,773684	0,780714	0,777484	0,778365	0,777586	0,778345	0,776151	0,770740	0,775457	0,779634
	6	0,726290	0,726397	0,733038	0,730551	0,731243	0,730454	0,729055	0,743586	0,742816	0,740800	0,731819	0,729269	0,732164	0,732143	0,738116	0,737053
	7	0,813248	0,819284	0,818750	0,822815	0,819853	0,817535	0,816646	0,820324	0,821159	0,808467	0,813447	0,819193	0,819407	0,819203	0,812562	0,822845
	8	0,706419	0,707059	0,720177	0,718174	0,709447	0,705621	0,718496	0,720930	0,720826	0,723124	0,716228	0,715010	0,709383	0,708879	0,719643	0,712668
	9	0,736186	0,738531	0,740990	0,749490	0,737776	0,732121	0,740719	0,755303	0,751916	0,744390	0,749653	0,736850	0,742575	0,741761	0,754623	0,749701
	10	0,742202	0,748830	0,747922	0,747038	0,752898	0,747768	0,751452	0,745552	0,740067	0,741588	0,751753	0,756611	0,746708	0,746376	0,745390	0,742559
6	1	0,766123	0,765024	0,772033	0,759514	0,766771	0,765333	0,764555	0,769771	0,770899	0,774294	0,763263	0,765894	0,770252	0,758311	0,763612	0,767313
	2	0,756959	0,759793	0,757332	0,761981	0,751141	0,761391	0,764881	0,767023	0,766263	0,759791	0,764155	0,762220	0,772109	0,755982	0,758617	0,762664
	3	0,759662	0,754057	0,758833	0,767409	0,761206	0,766654	0,765350	0,772025	0,768290	0,773865	0,760273	0,763918	0,763043	0,753953	0,775675	0,763337
	4	0,785794	0,794295	0,806044	0,795382	0,793237	0,791461	0,787939	0,800116	0,798592	0,792846	0,788344	0,791935	0,797411	0,795718	0,800259	0,796411
	5	0,815981	0,806225	0,814328	0,812024	0,811627	0,812229	0,812440	0,808938	0,815015	0,804793	0,815447	0,815043	0,813111	0,811505	0,818195	0,811972
	6	0,751873	0,754087	0,754368	0,748905	0,754657	0,748842	0,753166	0,758561	0,757601	0,754840	0,753282	0,757337	0,755393	0,752595	0,755042	0,754245
	7	0,861363	0,868001	0,870301	0,863077	0,866997	0,873212	0,874458	0,870267	0,869097	0,861389	0,869096	0,863128	0,856582	0,867964	0,865382	0,866127
	8	0,776503	0,786221	0,789276	0,784549	0,778975	0,784551	0,784749	0,792148	0,786350	0,788135	0,787857	0,782584	0,778525	0,774427	0,778411	0,785915
	9	0,795036	0,803604	0,799617	0,799148	0,793504	0,795954	0,798433	0,807727	0,801432	0,805060	0,798450	0,797835	0,799131	0,790154	0,791879	0,801267
	10	0,806790	0,801388	0,802520	0,796431	0,807429	0,791652	0,806358	0,803201	0,802436	0,812169	0,809238	0,804190	0,810658	0,805929	0,807098	0,797806
8	1	0,810167	0,804814	0,807542	0,806443	0,810810	0,807721	0,808374	0,821594	0,810479	0,806840	0,805776	0,809672	0,802276	0,808366	0,803907	0,814825
	2	0,801312	0,803123	0,806677	0,807826	0,806324	0,810636	0,807642	0,796106	0,809678	0,803880	0,801191	0,813975	0,800529	0,819873	0,804391	0,798143

Ek Tablo 15'in devamı

	3	0,796223	0,789586	0,788961	0,796264	0,797637	0,796248	0,794172	0,796142	0,803395	0,799326	0,790385	0,786133	0,798420	0,796390	0,793688	0,797045
	4	0,834948	0,825920	0,829251	0,830379	0,832924	0,837646	0,841745	0,839510	0,836284	0,835091	0,831455	0,831095	0,844743	0,832463	0,833645	0,837316
	5	0,842047	0,837981	0,835295	0,841192	0,835560	0,841602	0,842972	0,846719	0,845173	0,838706	0,840129	0,841285	0,839628	0,842286	0,842711	0,842903
	6	0,772402	0,775366	0,773964	0,772556	0,773939	0,772736	0,778042	0,772840	0,775788	0,776234	0,772265	0,781062	0,774043	0,771733	0,771530	0,775072
	7	0,889473	0,898433	0,903048	0,895245	0,900180	0,901042	0,895239	0,904718	0,902742	0,907838	0,904941	0,900369	0,898885	0,898636	0,904574	0,901818
	8	0,825346	0,828222	0,824064	0,839828	0,836969	0,833298	0,829192	0,828153	0,811932	0,829156	0,821885	0,824035	0,830871	0,825451	0,837271	0,839995
	9	0,829802	0,832135	0,837011	0,832830	0,831671	0,827345	0,831877	0,829945	0,830773	0,836461	0,828567	0,832600	0,835663	0,828579	0,830152	0,839124
	10	0,845073	0,831098	0,840773	0,839662	0,836983	0,833048	0,840360	0,835740	0,831714	0,835669	0,839403	0,847414	0,844665	0,839114	0,841149	0,839148
10	1	0,832334	0,837250	0,837736	0,839323	0,833566	0,830333	0,839304	0,839956	0,838543	0,839839	0,837164	0,838173	0,841028	0,835954	0,834868	0,843715
	2	0,824103	0,833614	0,845230	0,835842	0,837306	0,835418	0,834789	0,842102	0,840658	0,836775	0,834851	0,830839	0,833505	0,840663	0,841419	0,836857
	3	0,823160	0,812786	0,823099	0,815669	0,824196	0,816948	0,815557	0,825736	0,823642	0,823553	0,824366	0,825133	0,815458	0,817836	0,821918	0,825001
	4	0,849387	0,854392	0,859835	0,862151	0,863223	0,858857	0,854146	0,860923	0,867551	0,865602	0,857602	0,856706	0,864945	0,852820	0,865104	0,858800
	5	0,862282	0,864722	0,865314	0,863288	0,862889	0,866120	0,861684	0,863589	0,866553	0,868852	0,866439	0,860652	0,864964	0,862849	0,862215	0,863226
	6	0,793029	0,794321	0,796640	0,790585	0,796172	0,794724	0,793924	0,793166	0,793206	0,792632	0,793411	0,796224	0,792514	0,794678	0,794268	0,794229
	7	0,920141	0,919358	0,918159	0,919202	0,918401	0,920825	0,918519	0,914376	0,922292	0,922956	0,915910	0,921540	0,919916	0,921081	0,918084	0,917040
	8	0,862052	0,850887	0,864531	0,865872	0,862541	0,852011	0,865859	0,861922	0,852076	0,867192	0,854989	0,865263	0,864673	0,856417	0,862369	0,864183
	9	0,850947	0,856071	0,857492	0,856202	0,862269	0,856382	0,859920	0,852097	0,859626	0,859176	0,856405	0,856519	0,853830	0,858550	0,856928	0,853214
	10	0,850190	0,860577	0,857787	0,853905	0,853263	0,865544	0,865559	0,853979	0,865416	0,862676	0,862922	0,858852	0,854410	0,861890	0,856532	0,863819
12	1	0,860549	0,856930	0,858154	0,870016	0,862285	0,863542	0,864429	0,861280	0,863483	0,862398	0,859368	0,862984	0,861860	0,866684	0,857819	0,859556
	2	0,864151	0,854890	0,854943	0,864960	0,865157	0,865684	0,869693	0,862518	0,867998	0,870977	0,868477	0,860264	0,866397	0,860288	0,868107	0,859307
	3	0,838424	0,836540	0,842206	0,838469	0,835541	0,835457	0,829672	0,835761	0,840101	0,839744	0,839882	0,841829	0,835300	0,841999	0,839920	0,841473
	4	0,877861	0,875327	0,885592	0,875166	0,880291	0,883591	0,876004	0,881038	0,881559	0,874187	0,876236	0,877260	0,876919	0,872119	0,874223	0,879136
	5	0,881309	0,879314	0,880642	0,884164	0,877316	0,879619	0,879335	0,882463	0,879104	0,884743	0,881059	0,883578	0,881971	0,873339	0,880960	0,879533
	6	0,808983	0,811673	0,810159	0,809085	0,811206	0,812751	0,810821	0,813974	0,811964	0,813536	0,808955	0,813222	0,809358	0,814145	0,809470	0,806345
	7	0,937111	0,933832	0,925571	0,934659	0,935473	0,928660	0,933983	0,933700	0,932050	0,931029	0,931570	0,931111	0,933451	0,931734	0,929538	0,935529
	8	0,889546	0,877519	0,876142	0,889280	0,887070	0,888252	0,883297	0,890338	0,886023	0,889313	0,883876	0,893831	0,884472	0,880145	0,885478	0,883918
	9	0,872020	0,871594	0,872672	0,866727	0,871233	0,878546	0,876636	0,881411	0,872986	0,874091	0,873756	0,876312	0,876920	0,877469	0,878292	0,881991
	10	0,876251	0,878120	0,881275	0,870730	0,876907	0,876892	0,879702	0,881291	0,869743	0,881365	0,879750	0,878928	0,876212	0,877253	0,877682	0,871592

Ek Tablo 16. Kapur entropisi ve $maxFEs = 500 \times m$ için algoritmaların FSIM sonuçları

m	I	ABC	CS	GWO	HHO	MFO	SCA	SSA	WChOA	Case-1	Case-2	Case-3	Case-4	Case-5	Case-6	Case-7	Case-8
2	1	0,600165	0,600701	0,600649	0,601649	0,604435	0,603602	0,601581	0,612266	0,612938	0,611468	0,611076	0,609459	0,610075	0,609263	0,609043	0,612033
	2	0,605814	0,608722	0,613241	0,615376	0,612906	0,612789	0,609198	0,622897	0,624744	0,621510	0,619380	0,615898	0,618375	0,616935	0,619432	0,621266
	3	0,643269	0,643538	0,643771	0,647363	0,649438	0,646664	0,647969	0,652910	0,653063	0,651808	0,651741	0,650667	0,647822	0,650803	0,654196	0,649630
	4	0,660504	0,664841	0,658676	0,660464	0,655970	0,662709	0,657093	0,677379	0,676644	0,677346	0,668831	0,668490	0,664376	0,665866	0,675892	0,673212
	5	0,717086	0,715786	0,718200	0,719307	0,718400	0,719319	0,720637	0,717515	0,719708	0,718431	0,719509	0,719648	0,719521	0,718194	0,720105	0,719959
	6	0,701688	0,699209	0,698818	0,697113	0,699118	0,700261	0,697044	0,701907	0,699750	0,701799	0,702042	0,701077	0,701418	0,702712	0,703495	0,701968
	7	0,707079	0,705102	0,707706	0,707180	0,710560	0,709181	0,708982	0,708123	0,713322	0,718109	0,713769	0,709752	0,715921	0,716119	0,720278	0,709864
	8	0,595274	0,600232	0,600899	0,603774	0,599555	0,600688	0,592371	0,616823	0,610148	0,612810	0,607022	0,606376	0,610250	0,604264	0,609921	0,607233
	9	0,639945	0,638185	0,639894	0,639302	0,640651	0,637151	0,645465	0,653380	0,659220	0,660018	0,660661	0,662657	0,647632	0,649434	0,651237	0,662700
	10	0,630386	0,639656	0,643834	0,649695	0,648040	0,639543	0,642548	0,633171	0,636041	0,636074	0,625773	0,633200	0,642821	0,637616	0,642441	0,632982
4	1	0,706981	0,706743	0,700379	0,702314	0,709330	0,695068	0,699929	0,711737	0,708368	0,715149	0,715455	0,707630	0,699432	0,704585	0,711351	0,715622
	2	0,689124	0,689362	0,702519	0,698103	0,695846	0,693001	0,691142	0,703393	0,709898	0,716349	0,701474	0,710524	0,703437	0,697914	0,710175	0,699512
	3	0,718300	0,717727	0,715638	0,716822	0,715249	0,718364	0,715891	0,731611	0,729190	0,732904	0,727486	0,731489	0,714782	0,718324	0,728646	0,731740
	4	0,735775	0,734959	0,734483	0,747428	0,736277	0,742551	0,731190	0,754809	0,750111	0,765013	0,742980	0,753565	0,742558	0,738808	0,748909	0,733752
	5	0,775989	0,772560	0,777574	0,775619	0,773849	0,776989	0,777437	0,779758	0,777953	0,778739	0,778650	0,779956	0,778326	0,772582	0,779760	0,781460
	6	0,727553	0,731512	0,725960	0,724794	0,731725	0,731711	0,727937	0,741208	0,745229	0,752152	0,738543	0,740325	0,738870	0,732408	0,743495	0,736812
	7	0,811157	0,811410	0,811619	0,820482	0,819211	0,813597	0,817834	0,818656	0,816367	0,814614	0,815633	0,811279	0,817615	0,817079	0,819326	0,817990
	8	0,713416	0,713718	0,716470	0,711531	0,711274	0,716699	0,711317	0,725957	0,729646	0,724356	0,725553	0,713886	0,712542	0,717434	0,723118	0,723657
	9	0,744728	0,735195	0,735393	0,738221	0,738252	0,738190	0,748647	0,755686	0,752367	0,748490	0,755083	0,744745	0,755520	0,736400	0,752540	0,750337
	10	0,752493	0,751707	0,746117	0,758866	0,767405	0,757417	0,762904	0,739471	0,740213	0,740509	0,740649	0,738056	0,749628	0,752939	0,744537	0,751193
6	1	0,765848	0,756813	0,764509	0,764609	0,763449	0,772094	0,769661	0,770236	0,771450	0,770537	0,768226	0,773584	0,771997	0,766804	0,768182	0,776545
	2	0,756531	0,767657	0,756012	0,761147	0,766913	0,747157	0,756979	0,774175	0,772451	0,770112	0,772930	0,762860	0,772730	0,754773	0,777241	0,772050
	3	0,761297	0,760770	0,765795	0,764171	0,759115	0,764191	0,757905	0,772636	0,772037	0,773160	0,768555	0,764792	0,766801	0,759325	0,768015	0,771317
	4	0,802319	0,794071	0,795843	0,800485	0,788249	0,802213	0,790696	0,804661	0,808528	0,799068	0,804910	0,797746	0,788577	0,787884	0,807567	0,802036
	5	0,809503	0,807078	0,811856	0,809815	0,812213	0,811505	0,812302	0,813098	0,815143	0,811624	0,809979	0,812556	0,810706	0,811835	0,816740	0,809690
	6	0,753526	0,748041	0,751216	0,755118	0,753987	0,753636	0,748364	0,757810	0,758837	0,754237	0,756600	0,751734	0,750860	0,752832	0,757360	0,759192
	7	0,871873	0,866797	0,865291	0,869095	0,864260	0,868651	0,868998	0,863636	0,864184	0,869231	0,862648	0,868248	0,870950	0,872172	0,865961	0,864544
	8	0,786601	0,779603	0,792321	0,782765	0,772886	0,782727	0,778424	0,794902	0,782701	0,786647	0,780853	0,783478	0,782144	0,786419	0,785626	0,789234
	9	0,785930	0,795711	0,791064	0,794797	0,798796	0,801047	0,796590	0,809098	0,803609	0,802436	0,799357	0,793863	0,793940	0,802317	0,804551	0,800076
	10	0,799338	0,800745	0,808731	0,803517	0,815052	0,802872	0,799780	0,796181	0,795882	0,796665	0,801778	0,794506	0,801275	0,795336	0,805590	0,798004
8	1	0,808845	0,811946	0,808527	0,805422	0,813315	0,802658	0,809097	0,812005	0,819093	0,806105	0,806650	0,808977	0,806988	0,805436	0,811768	0,811050
	2	0,814685	0,800955	0,800094	0,809999	0,804419	0,799937	0,803891	0,810232	0,813934	0,815097	0,808237	0,806407	0,806465	0,811445	0,800521	0,810683

Ek Tablo 16'ın devamı

	3	0,787501	0,794880	0,785165	0,802855	0,789834	0,793521	0,782739	0,808025	0,797413	0,798493	0,790430	0,799536	0,798232	0,796313	0,796766	0,799236
	4	0,830365	0,820810	0,834473	0,835933	0,826759	0,826689	0,834870	0,833550	0,838390	0,835030	0,836667	0,836320	0,831700	0,822924	0,830748	0,839393
	5	0,839517	0,837320	0,843916	0,841904	0,843246	0,838897	0,837837	0,841442	0,841032	0,843492	0,841958	0,837800	0,840916	0,835906	0,841382	0,835649
	6	0,774915	0,770451	0,777932	0,775590	0,776435	0,773577	0,772989	0,775232	0,776527	0,773667	0,778140	0,772043	0,775607	0,777573	0,778707	0,777953
	7	0,894125	0,895002	0,899238	0,898210	0,901216	0,898795	0,898418	0,897986	0,894940	0,896720	0,898087	0,905157	0,899392	0,894600	0,898767	0,902402
	8	0,828924	0,829025	0,831424	0,834944	0,833111	0,828390	0,826814	0,831948	0,839372	0,830308	0,833373	0,816461	0,832514	0,820866	0,826595	0,834284
	9	0,825696	0,835256	0,829260	0,831712	0,832977	0,826881	0,827542	0,830111	0,835159	0,831576	0,833973	0,834515	0,836653	0,826134	0,833181	0,828210
	10	0,843928	0,835456	0,837919	0,838384	0,845220	0,841330	0,834902	0,826262	0,832102	0,835463	0,846476	0,832081	0,829266	0,840049	0,828500	0,830020
10	1	0,837988	0,830335	0,838906	0,836350	0,833281	0,837302	0,831512	0,840920	0,834197	0,840915	0,837198	0,841447	0,841846	0,831777	0,834919	0,845446
	2	0,840796	0,826289	0,829985	0,827167	0,836452	0,840467	0,820998	0,838722	0,840654	0,841035	0,841134	0,830108	0,838116	0,842641	0,838842	0,835070
	3	0,820822	0,821005	0,824749	0,814534	0,820643	0,814896	0,811811	0,820748	0,826143	0,821988	0,813839	0,810378	0,822080	0,826136	0,821528	0,818435
	4	0,858750	0,852463	0,862032	0,855804	0,852521	0,861120	0,858420	0,862215	0,861697	0,857158	0,859471	0,851195	0,857158	0,869877	0,864688	0,853852
	5	0,864841	0,865805	0,863395	0,862856	0,863338	0,862691	0,863896	0,864284	0,862760	0,865211	0,868637	0,869105	0,861533	0,868039	0,864423	0,866167
	6	0,791339	0,793232	0,795362	0,796534	0,793897	0,795671	0,791146	0,793730	0,794341	0,795121	0,794618	0,797577	0,791127	0,797564	0,791938	0,793813
	7	0,913444	0,917012	0,920706	0,918826	0,919370	0,915463	0,922181	0,916815	0,917349	0,921798	0,919215	0,918478	0,912787	0,920295	0,922259	0,920678
	8	0,858017	0,856423	0,866719	0,866500	0,867110	0,870956	0,860518	0,859757	0,861227	0,862335	0,862411	0,850825	0,849225	0,855127	0,851985	0,860296
	9	0,853931	0,860841	0,851662	0,856122	0,851486	0,853734	0,859157	0,856527	0,858086	0,853183	0,848841	0,854400	0,855782	0,850527	0,850008	0,851685
	10	0,862764	0,862477	0,863031	0,863473	0,862943	0,865819	0,859230	0,849380	0,849630	0,864651	0,862267	0,853717	0,856552	0,861256	0,859681	0,861603
12	1	0,855549	0,861825	0,864486	0,868473	0,861620	0,862143	0,859480	0,864978	0,858737	0,858045	0,867107	0,866143	0,867136	0,867070	0,866450	0,863015
	2	0,855168	0,859588	0,860546	0,852922	0,853241	0,864873	0,858161	0,871715	0,863086	0,861768	0,859931	0,864998	0,852170	0,863297	0,857051	0,861074
	3	0,834571	0,835471	0,842328	0,843503	0,844425	0,840734	0,840616	0,841868	0,841904	0,839749	0,843610	0,843135	0,839570	0,840482	0,843758	0,845060
	4	0,878787	0,876047	0,878030	0,876725	0,878738	0,883273	0,876748	0,879722	0,871221	0,881504	0,882106	0,876278	0,879773	0,880240	0,882676	0,874953
	5	0,880413	0,882835	0,883547	0,880711	0,882076	0,885475	0,884111	0,882610	0,880240	0,881009	0,877549	0,882975	0,881416	0,880007	0,878237	0,882201
	6	0,813623	0,810290	0,811638	0,809696	0,810008	0,814318	0,814344	0,810697	0,809469	0,808328	0,808646	0,815048	0,811231	0,812135	0,810017	0,812246
	7	0,930926	0,932765	0,931808	0,933251	0,934916	0,928982	0,933480	0,938692	0,928118	0,933223	0,933887	0,929972	0,934834	0,931807	0,934030	0,937069
	8	0,886524	0,884771	0,883058	0,887027	0,882081	0,881811	0,882585	0,878875	0,883142	0,886483	0,884005	0,888728	0,875538	0,880035	0,885581	0,886599
	9	0,868466	0,873736	0,877183	0,878849	0,875576	0,881246	0,880504	0,881540	0,874636	0,878473	0,875715	0,879977	0,875974	0,877022	0,874024	0,871738
	10	0,877353	0,881927	0,881135	0,878339	0,879469	0,881124	0,875013	0,875840	0,882276	0,879344	0,877192	0,879097	0,883688	0,871763	0,871547	0,874947

ÖZGEÇMİŞ

Samoua ALSAMOUA, Yerel bir okulda ilköğretimini tamamladıktan sonra, 2015 yılında Walid-Shaban Lisesi'nde lise eğitimini bitirdi. Aynı yıl, Tishreen Üniversitesi'nde Telekomünikasyon ve Elektronik Mühendisliği lisans eğitimine başladı ve 2020 yılında 88.80'lik bir not ortalamasıyla onur derecesiyle mezun oldu. Lisans eğitimleri sırasında, üç yıl üst üste (2017, 2018 ve 2019) Akademik Başarıda Üstün Performans için prestijli Al-Basel Sertifikası ile ödüllendirildi. Lisans başarılarının ardından, Samoua 2022 yılında Türkiye'de Karadeniz Teknik Üniversitesi'nde yüksek lisans programına başladı. Arapça ve İngilizce dillerinde akıcı olan Samoua, telekomünikasyon, yapay zeka ve yazılım mühendisliği gibi alanlarda çalışmalar yapmaktadır.

Günay Yılmaz, A., & Alsamoua, S. (2025). Meta sezgisel arama algoritmalarının çok seviyeli görüntü eşikleme performanslarının karşılaştırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 14(1), 1-1 (TR-Dizin).