

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



OPTİMİZASYON ALGORİTMALARININ, GÖRÜNTÜ İŞLEME
VE MAKİNE ÖĞRENMESİ UYGULAMALARINA
ENTEGRASYONU

Yağmur ÖLMEZ

Doktora Tezi

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Kontrol Sistemleri Bilim Dalı

ŞUBAT 2024

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Mekatronik Mühendisliği Anabilim Dalı

Doktora Tezi

OPTİMİZASYON ALGORİTMALARININ, GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENMESİ UYGULAMALARINA ENTEGRASYONU

Tez Yazarı
Yağmur ÖLMEZ

Danışman
Doç. Dr. Gonca ÖZMEN KOCA

İkinci Danışman
Prof. Dr. Abdulkadir ŞENGÜR

ŞUBAT 2024
ELAZIĞ

T.C.
FIRAT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Mekatronik Mühendisliği Anabilim Dalı

Doktora Tezi

Başlığı:	Optimizasyon Algoritmalarının, Görüntü İşleme ve Makine Öğrenmesi Uygulamalarına Entegrasyonu
Yazarı:	Yağmur ÖLMEZ
İlk Teslim Tarihi:	13.01.2024
Savunma Tarihi:	15.02.2024

TEZ ONAYI

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına göre hazırlanan bu tez aşağıda imzaları bulunan jüri üyeleri tarafından değerlendirilmiş ve akademik dinleyicilere açık yapılan savunma sonucunda OYBİRLİĞİ ile kabul edilmiştir.

Danışman:	Doç. Dr. Gonca ÖZMEN KOCA Fırat Üniversitesi, Teknoloji Fakültesi	İmza Onayladım
Başkan:	Doç. Dr. Cafer BAL Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Yaman Akbulut Fırat Üniversitesi, Teknoloji Fakültesi	Onayladım
Üye:	Doç. Dr. Ömer FARUK ALÇİN İnönü Üniversitesi, Mühendislik Fakültesi	Onayladım
Üye:	Doç. Dr. Ümit BUDAK Bitlis Eren Üniversitesi, Mühendislik-Mimarlık Fakültesi	Onayladım

Bu tez, Enstitü Yönetim Kurulunun/...../20..... tarihli toplantısında tescillenmiştir.

İmza

Prof. Dr. Burhan ERGEN
Enstitü Müdürü

BEYAN

Fırat Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım “Optimizasyon Algoritmalarının, Görüntü İşleme ve Makine Öğrenmesi Uygulamalarına Entegrasyonu” Başlıklı Doktora Tezimin içindeki bütün bilgilerin doğru olduğunu, bilgilerin üretilmesi ve sunulmasında bilimsel etik kurallarına uygun davrandığımı, kullandığım bütün kaynakları atıf yaparak belirttiğimi, maddi ve manevi desteği olan tüm kurum/kuruluş ve kişileri belirttiğimi, burada sunduğum veri ve bilgileri unvan almak amacıyla daha önce hiçbir şekilde kullanmadığımı beyan ederim.

15.02.2024

Yağmur ÖLMEZ



ÖNSÖZ

Bu tez çalışması, farklı karakteristiklere sahip görüntülerin bölütlenmesi, EEG sinyallerinden duygu tanımlama gibi problemler için optimizasyon algoritmalarının adapte edilmesini ve daha etkin algoritmaların geliştirilmesini içermektedir. Bu kapsamda, görüntü işleme ve makine öğrenmesi alanlarındaki uygulamaların geliştirilmesinin yanı sıra, optimizasyon algoritmalarına yeni stratejilerin eklenerek eksikliklerinin giderilmesine yönelik bir dizi yöntem geliştirilmiştir ve geliştirilmeye devam edilmektedir. Bu yöntemlerde, mevcut algoritmaların performanslarını artırmak ve çeşitli uygulama alanlarında daha etkili çözümler sunmak amaçlanmıştır.

Bu süreçte birlikte çalışmaktan memnuniyet duyduğum, tecrübesiyle yol göstererek takıldığım tüm problemleri hızlı bir şekilde çözüme ulaştırmada içtenlikle bana yardım eden, her konuda rehber olan ve hayatımın her alanında örnek aldığım, ömrüm boyunca faydalanacağım iyi bir bilimsel çalışma disiplini kazandıran kıymetli danışman hocalarım Doç. Dr. Gonca ÖZMEN KOCA ve Prof. Dr. Abdulkadir ŞENGÜR'e sonsuz teşekkürlerimi sunarım.

Bütün zorluklarda anlayışlı ve hep yanımda olan ve beni destekleyen sevgili eşim Hayrettin Bey'e, huzur ve neşe kaynağım minik kızım Hüma'ma, beni hiç yalnız bırakmayan kıymetli anneme teşekkür ederim.

Bu tezin optimizasyon algoritmaları, görüntü işleme, makine öğrenmesi ve bu alanlarda kullanılan yöntemlerin geliştirilmesine yönelik çalışmalar yapan tüm araştırmacılara katkı sağlamasını temenni ederim.

Saygılarımla.

Yağmur ÖLMEZ
ELAZIĞ, 2024

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ÖZET	vii
ABSTRACT	viii
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xi
EKLER LİSTESİ	xiii
SİMGELER	xiv
KISALTMALAR	xv
1. GİRİŞ	1
1.1. Literatür İncelemesi	1
1.1.1. Çok Seviyeli Görüntü Eşikleme	1
1.1.2. EEG Sinyallerinden Duygu Tanımlama	6
1.1.3. Optimizasyon Algoritmaları	7
1.2. Tezin Amacı	10
1.3. Tezin Literatüre Katkıları	12
1.4. Tezin Organizasyonu	13
2. ÖN BİLGİLER.....	15
2.1. Optimizasyon Algoritmaları	15
2.1.1. Altın Sinus Algoritması	16
2.1.2. Rao1 Algoritması	17
2.1.3. Parçacık Sürü Algoritması.....	18
2.2. Optimizasyon Algoritmalarına Dayalı Görüntü Eşikleme Yöntemleri.....	18
2.2.1. Renyi'nin Entropisi	19
2.2.2. Otsu'nun Maksimum Varyansı	20
2.3. Değerlendirme Ölçütleri	21
2.3.1. Yapılandırılmış Benzerlik İndeksi.....	21
2.3.2. Özellik Benzerlik İndeksi.....	21
2.3.3. Tepe Sinyal-Gürültü Oranı	22
2.3.4. Ortalama Karesel Hata	22
2.3.5. Olasılık Rand Endeksi	22
2.3.6. Bilgi Varyasyonu.....	22
2.3.7. Sınır Yer Değiştirme Hatası	23
2.3.8. Global Tutarlılık Hatası	23
2.3.9. Ortalama Fark.....	23
2.3.10. Maksimum Fark	24
2.3.11. Normalize Edilmiş Mutlak Fark.....	24
2.3.12. Standart Sapma.....	24
3. MATERYAL VE METOT	25
3.1. Uygulanan Problemler ve Verisetleri	25
3.1.1. Test Fonksiyonları	25
3.1.2. Klasik Mühendislik Tasarım Problemleri	26

3.1.3. Berkeley-Benchmark Veri Seti (BSDS300).....	30
3.1.4. ISIC2017 Deri Kanseri Görüntüleri Veri Seti	30
3.1.5. BIDC Göğüs Kanseri Görüntüleri Veri Seti.....	31
3.1.6. DEAP-EEG Sinyalleri Veri Seti.....	31
3.2. Çok Seviyeli Görüntü Eşikleme	32
3.2.1. Altın Sinus Algoritması.....	32
3.2.2. Kaotik Karşıt Öğrenme Tabanlı Altın Sinüs Algoritması	36
3.2.3. Kaotik Olarak Zenginleştirilmiş Adaptif Rao Algoritması	41
3.2.4. Parçacık Sürü Optimizasyon Algoritması	47
3.2.5. Ziyaret Tablosu Stratejisine Dayalı PSO Yöntemi.....	51
3.3. Duygu Sınıflandırması.....	56
4. BULGULAR VE TARTIŞMA.....	63
4.1. GoldSa Yöntemi ile Çok Seviyeli Görüntü Eşikleme.....	63
4.2. Kaotik Karşıt Öğrenme Tabanlı GoldSa ile Göğüs Kanseri Görüntülerinin Bölütlenmesi	69
4.3. Kaotik Olarak Zenginleştirilmiş Rao Algoritması ile Adaptif Çok Seviyeli Görüntü Eşikleme	85
4.4. PSO Algoritması ile Çok Seviyeli Görüntü Eşikleme	94
4.5. PS-VTS Yöntemi ile Deri Kanseri Görüntülerinin Bölütlenmesi	97
4.6. PS-VTS Yöntemi ile Otomatik Duygu Sınıflandırması.....	111
5. SONUÇLAR.....	122
ÖNERİLER	130
KAYNAKLAR.....	131
EKLER	142
ÖZGEÇMİŞ	

ÖZET

Optimizasyon Algoritmalarının, Görüntü İşleme ve Makine Öğrenmesi Uygulamalarına Entegrasyonu

Yağmur ÖLMEZ

Doktora Tezi

FIRAT ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

Mekatronik Mühendisliği Anabilim Dalı

Şubat 2024, Sayfa: xv + 141

Optimizasyon algoritmaları, günümüzde en önemli ve en çok çalışılan araştırma konularından birisidir. Mühendislik, bilim, enerji, bilgisayar vs. gibi neredeyse tüm alanlarda yer alır ve temel süreçlerin içinde pek çok amaç ile bulunabilir. Uygulamalarda kullanılan yöntemlerin daha etkin ve adaptif hale getirilmesine katkı sağlar. Ancak gerçek dünyadaki bilimsel ve mühendislik problemlerinin karmaşıklığından dolayı mevcut basit optimizasyon algoritmaları yetersiz kalabilmektedir. Bu nedenle, daha dayanıklı ve pek çok disiplindeki küresel optimizasyon problemlerinin çözümünde başarılı olabilecek yöntemlerin geliştirilmelerine ihtiyaç duyulmaktadır.

Bu tez çalışmasında metasezgisel algoritmaların görüntü bölütleme ve makine öğrenmesi yöntemlerine entegre edilerek bu yöntemlerin ve uygulamadaki başarımlarının geliştirilmesi amaçlanmıştır. Bu kapsamda, geliştirilen yöntemler ile yapılan çalışmalar şu şekildedir:

- ✓ Altın Sinüs Algoritması II'ye Dayalı Çok Seviyeli Görüntü Eşikleme
- ✓ Küresel Optimizasyon Problemleri ve Göğüs Kanseri Görüntülerinin Bölütlenmesi için Geliştirilen Kaotik Karşıt Öğrenme Tabanlı Altın Sinüs Algoritması
- ✓ Kaotik Olarak Zenginleştirilmiş Rao Algoritması ile Adaptif Çok Seviyeli Görüntü Eşikleme
- ✓ Parçacık Sürü Optimizasyonuna Dayalı Çok Seviyeli Eşikleme
- ✓ Ziyaret Tablosu ve Çoklu Arama Stratejilerine Dayalı PSO Yöntemi ile Çok seviyeli Eşikleme Yöntemi
- ✓ Ziyaret Tablosu ve Çoklu Arama Stratejilerine Dayalı Ayrık PSO Yöntemi ile EEG Sinyallerinden Duygu Sınıflandırması.

Geliştirilen bu yöntemlerde çeşitli disiplinlerdeki küresel problemlerin çözümüne odaklanılmıştır. Bu kapsamda; test fonksiyonları, klasik mühendislik problemleri, yapay görüntüler, deri ve göğüs kanseri görüntüleri, çeşitli amaçlarla çekilmiş farklı özellikteki görüntüler ile EEG sinyalleri üzerinde deneysel çalışmalar gerçekleştirilmiş olup önerilen yöntemlerin üstünlükleri literatürde önerilen yöntemler ve sonuçları karşılaştırılarak çeşitli ölçüm indeksleri açısından gösterilmiştir.

Anahtar Kelimeler: Çok seviyeli eşikleme, görüntü bölütleme, metasezgisel algoritmalar, EEG, kanal-ritim seçimi, deri kanseri, göğüs kanseri, optimizasyon.

ABSTRACT

Integration of Optimization Algorithms into Image Processing and Machine Learning Applications

Yağmur ÖLMEZ

Ph.D. Thesis

FIRAT UNIVERSITY
Graduate School of Natural and Applied Sciences
Department of Mechatronics Engineering

February 2024, Pages: xv + 141

Optimization is one of the most important and most studied research topics today. It takes place in almost all fields such as engineering, science, energy, computers, etc. and can be found in basic processes for many purposes. It contributes to making the methods used in applications more effective and adaptive. However, due to the complexity of real-world scientific and engineering problems, existing simple optimization algorithms may be insufficient. Therefore, there is a need to develop methods that are more robust and can be successful in solving global optimization problems in many disciplines.

In this thesis study, it is aimed to integrate metaheuristic algorithms into image segmentation and machine learning methods and improve the performance of these methods and their applications. In this context, the studies carried out with the developed methods are as follows:

- ✓ Multi-Level Image Thresholding Based on Golden Sine Algorithm II
- ✓ Global Optimization Problems and Chaotic Adversarial Learning Based Golden Sine Algorithm Developed for Breast Cancer Image Segmentation
- ✓ Adaptive Multi-Level Image Thresholding with Chaotically Augmented Rao Algorithm
- ✓ Multi-Level Thresholding Based on Particle Swarm Optimization
- ✓ Multi-level Thresholding Method with PSO Method Based on Visit Table and Multiple Search Strategies
- ✓ Emotion Classification from EEG Signals with Discrete PSO Method Based on Visit Table and Multiple Search Strategies.

These developed methods focus on solving global problems in various disciplines. In this context; Experimental studies have been carried out on test functions, classical engineering problems, artificial images, skin and breast cancer images, images with different characteristics taken for various purposes and EEG signals, and the advantages of the proposed methods have been shown in terms of various measurement indices by comparing the methods and their results proposed in the literature.

Keywords: Multilevel thresholding, image segmentation, metaheuristic algorithms, EEG channel and rhythm selection, skin cancer, breast cancer, optimization.

ŞEKİLLER LİSTESİ

	Sayfa
Şekil 2.1 Metasezgisel Algoritmaların Sınıflandırılması.....	16
Şekil 2.2. Metasezgisel yöntemlere dayalı görüntü bölütleme akış diagramı.....	19
Şekil 3.1. Çekme/Basma yay tasarım modeli	26
Şekil 3.2. Kaynaklı giriş tasarım modeli	27
Şekil 3.3. Basınçlı boru tasarım modeli.....	29
Şekil 3.4. Üç çubuklu kafes tasarım modeli	30
Şekil 3.5.BSDS300 verisetinden alınan örnek görüntüler	30
Şekil 3.6. ISIC2017 verisetinden alınan örnek görüntüler.....	31
Şekil 3.7.BIDC verisetinden alınan örnek görüntüler.....	31
Şekil 3.8. DEAP verisetinden alınan örnek bir EEG sinyali görüntüsü.....	32
Şekil 3.9 İki boyutlu NLM-GoldSa II yöntemine dayalı görüntü bölütleme akış şeması.....	34
Şekil 3.10. İki boyutlu yerel olmayan ortalamalar histogramı.....	34
Şekil 3.11. OBL stratejisi akış şeması	39
Şekil 3.12. Önerilen Co-GoldSa yöntemi akış şeması.....	41
Şekil 3.13. Önerilen yöntemin akış diagramı	45
Şekil 3.14. Seçilen test görüntülerinin referans görüntüleri	46
Şekil 3.15. 2D-YOH yöntemi akış şeması.....	50
Şekil 3.16. Önerilen yöntem ile parçacıkların konumunun güncellenmesi.	54
Şekil 3.17. Önerilen PS-VTS yönteminin akış şeması	56
Şekil 3.18. Beyin yapısı ve lobları.....	58
Şekil 3.19. Başlangıç popülasyonundan aday bir çözüm kümesinin örneği	61
Şekil 4.1. 1D ve 2D yerel olmayan ortalamalar histogram örnekleri	64
Şekil 4.2.Test Görüntüleri	67
Şekil 4.3. Örnek görüntünün üç farklı yöntemle bölütlenmesi: (a) 3-seviyeli bölütleme; (b) 5-seviyeli bölütleme; (c) referans görüntüler	69
Şekil 4.4. Invaziv Duktal Karsinoma göğüs patoloji görüntüleri.	77
Şekil 4.5. Test görüntüleri ve 1D&2D histogramları.	78
Şekil 4.6. Önerilen MTIS yönteminin akış şeması.	80
Şekil 4.7. Önerilen yöntem ile bölütlenmiş görüntüler.....	80
Şekil 4.8. Test görüntüsü 3 ve 4 için bölütlenen gri ölçekli ve renklendirilmiş görüntüler	82
Şekil 4.9. Tüm yöntemler için Renyi'nin entropisinin yakınsama eğrileri	84

Şekil 4.10. Orijinal görüntüler ve histogramları	86
Şekil 4.11. Yapay görüntü ve histogramları (a) orijinal görüntü, (b) 1d-histogram (c) 2D-histogram.....	87
Şekil 4.12. 5-seviyeli olarak oluşturulan yapay görüntüye ait (a) Uygunluk değerleri, (b) Hata grafikleri..	87
Şekil 4.13. Oluşturulan 3-seviyeli ve 4-seviyeli yapay görüntüler ve 1d histogramları	88
Şekil 4.14. (a) Orijinal görüntüler (b) Uygunluk değeri grafiği, (c) CPU zaman grafiği	89
Şekil 4.15. Rao algoritmasına uygulanan kaotik haritaların hesaplama süreleri (sn)	92
Şekil 4.16. CER algoritması ve diğer 5 algoritma için hesaplama süreleri (sn)	92
Şekil 4.17. Bölütlenmiş görüntüler	93
Şekil 4.18. 3 seviyeli eşiklemede PSO ve e-KGSA yöntemlerinin hesaplama süreleri (sn).....	96
Şekil 4.19. 5 seviyeli eşiklemede PSO ve e-KGSA yöntemlerinin hesaplama süreleri (sn).....	97
Şekil 4.20. Çalışmada kullanılan test görüntüleri	98
Şekil 4.21. (a) Deri kanseri görüntüleri görüntüleri, (b) 1D histogram, (c) 2D histogram	99
Şekil 4.22. Nitel analiz özeti,(a)Test fonksiyonları, (b) 1-boyutta yörünge,(c) Yakınsama eğrisi.	100
Şekil 4.23. Test fonksiyonlarının farklı algoritmalar ile yakınsama grafikleri	101
Şekil 4.24. PS-VTS algoritması ile bölütlenen görüntüler: (a) Orjinal görüntüler, (b) 2-seviyeli, (c) 3-seviyeli,(d) 4-seviyeli, and (e) 5-seviyeli olarak bölütlenmiş görüntüler.....	103
Şekil 4.25. Tüm deri kanseri görüntüleri için elde edilen ortalalama SSIM değerleri.....	110
Şekil 4.26. Tüm deri kanseri görüntüleri için elde edilen ortalalama FSIM değerleri.....	110
Şekil 4.27. Tüm deri kanseri görüntüleri için elde edilen ortalama PSNR değerleri.....	111
Şekil 4.28. EEG sinyali ve ritimleri.....	112
Şekil 4.29. EEG sinyallerinin ritim görüntüleri	113
Şekil 4.30. Model 1 ile optimum kanal ve ritim seçiminin akış şeması	113
Şekil 4.31. Model 2 ile optimum kanal ve ritim seçiminin akış şeması	114
Şekil 4.32. Model 1 için HV-LV sınıflandırmasında seçilen kanallar ile elde edilen doğruluk puanları ...	118
Şekil 4.33. Model 1 için HA-LA sınıflandırmasında seçilen kanallar ile elde edilen doğruluk puanları ...	118
Şekil 4.34. PSO ve PS-VTS ile Model 1 & Model 2 için doğruluk puanlarının karşılaştırılması	119

TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. Çeşitli Kaotik Haritaların Matematiksel Formülleri	44
Tablo 3.2. Algoritma parametrelerinin gösterimleri ve tanımları	47
Tablo 3.3. EEG sinyallerinin ritimleri ve özellikleri	58
Tablo 4.1. Önerilen yöntemin parametreleri	63
Tablo 4.2. Ortalama BDE & PRI değerleri	64
Tablo 4.3. Ortalama VOI & GCE değerleri	65
Tablo 4.4. Ortalama SSIM & FSIM değerleri	65
Tablo 4.5. Ortalama RMSE & PSNR değerleri	66
Tablo 4.6. Ortalama CC & AD değerleri	66
Tablo 4.7. Ortalama MD & NAE değerleri	67
Tablo 4.8. En iyi 3 optimizasyon yöntemleri ile yapılan 3-seviyeli eşikleme için eşik değeri, uygunluk değeri ve hesaplama süresi	68
Tablo 4.9. En iyi 3 optimizasyon yöntemleri ile yapılan 5-seviyeli eşikleme için eşik değeri, uygunluk değeri ve hesaplama süresi	68
Tablo 4.10. 3-seviyeli ve 5-seviyeli eşiklemede elde edilen optimum eşik değerleri	68
Tablo 4.11. GoldSa yönteminin uygulamasında kullanılan test fonksiyonları	70
Tablo 4.12. cGoldSa1 yönteminden elde edilen istatistiksel sonuçlar	71
Tablo 4.13. cGoldSa2 yönteminden elde edilen istatistiksel sonuçlar	72
Tablo 4.14. cGoldSa3 yönteminden elde edilen istatistiksel sonuçlar	72
Tablo 4.15. Co-GoldSa, GoldSa ve cGoldSa yöntemlerinin istatistiksel sonuçları	73
Tablo 4.16. Çekme/basma yay tasarım problemi için karşılaştırmalı sonuçlar	74
Tablo 4.17. Kaynaklı kiriş tasarım problemi için karşılaştırmalı sonuçlar	75
Tablo 4.18. Basınçlı boru tasarım problemi için karşılaştırmalı sonuçlar	75
Tablo 4.19. Üç çubuklu kafes tasarım problemi için karşılaştırmalı sonuçlar	76
Tablo 4.20. Önerilen yöntemin mevcut yöntemlerle klasik mühendislik problemleri için karşılaştırmalı sonuçları	76
Tablo 4.21. Elde edilen 2D Renyi'nin optimum entropi değerleri	79
Tablo 4.22. Tüm görüntülerin ortalama SSIM değeri	81
Tablo 4.23. Tüm görüntülerin ortalama FSIM değeri	81
Tablo 4.24. Tüm görüntülerin ortalama PSNR değeri	81
Tablo 4.25. Tüm yöntemler için elde edilen hesaplama süreleri	83
Tablo 4.26. Önerilen Rao algoritmaları ve 8 kaotik haritanın karşılaştırılması	90

Tablo 4.27. Farklı kaotik haritalarla geliştirilen Rao algoritmaları ile elde edilen beş örnek görüntü için optimum değerler.....	91
Tablo 4.28. Veri setindeki tüm görüntüler için 12 ölçüm indeksine göre farklı algoritmaların karşılaştırılması.....	94
Tablo 4.29. Çok seviyeli eşikleme için kullanılan algoritma parametreleri	95
Tablo 4.30. 3-seviyeli görüntü eşikleme için önerilen yöntemin diğer yöntemlerle karşılaştırması	95
Tablo 4.31. 5-seviyeli görüntü eşikleme için önerilen yöntemin diğer yöntemlerle karşılaştırması	96
Tablo 4.32. Bölütleme yönteminde kullanılan parametre değerleri	98
Tablo 4.33. Tüm seviyeler için elde edilen Renyi'nin optimum eşik değerleri (Görüntü 1- Görüntü 5)....	104
Tablo 4.34. Tüm seviyeler için elde edilen Renyi'nin optimum eşik değerleri (Görüntü 6- Görüntü 10) .	105
Tablo 4.35. Ortalama SSIM değerleri.	107
Tablo 4.36. Ortalama FSIM değerleri	108
Tablo 4.37. Ortalama PSNR değerleri	109
Tablo 4.38. PS-VTS algoritmasında kullanılan parametreler ve değerleri.....	115
Tablo 4.39. Model 1 için HV-LV ve HA-LA sınıflandırmasında seçilen optimum kanallar ve doğruluk değerleri	116
Tablo 4.40. Model 2 için HV-LV ve HA-LA sınıflandırmasında seçilen optimum kanallar ve doğruluk değerleri	117
Tablo 4.41. Model 1 için önerilen PS-VTS ve orjinal PSO ile seçilen optimum kanallar.	117
Tablo 4.42. Model 2 için önerilen PS-VTS ve orijinal PSO ile seçilen optimum kanallar.	117
Tablo 4.43. Optimum kanal-ritim seçim sürecinin hesaplama süreleri	120
Tablo 4.44. Geliştirilen yöntemin aynı veri seti kullanılarak geliştirilen diğer son teknoloji modellerle karşılaştırılması	120
Tablo 5.1. Yapılan Çalışmalar ve Başarımları	128

EKLER LİSTESİ

	Sayfa
Ek- 1: Test Fonksiyonları ve Özellikleri (F ₁ -F ₂₃).....	142
Ek- 2: Test Fonksiyonları ve Özellikleri (F ₂₃ -F ₄₂)	143
Ek- 3: Test Fonksiyonları ve Özellikleri (F ₄₃ -F ₅₀)	144
Ek- 4: Test fonksiyonlarının istatistiksel analizleri (F ₁ -F ₁₇)	145
Ek- 5: Test fonksiyonlarının istatistiksel analizleri (F ₁₈ -F ₃₄)	146
Ek- 6: Test fonksiyonlarının istatistiksel analizleri (F ₃₄ -F ₅₀).....	147
Ek- 7: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F ₁ -F ₁₁).....	148
Ek- 8: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F ₁₂ -F ₂₁).....	149
Ek- 9: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F ₂₁ -F ₂₅).....	150
Ek- 10: Önerilen Co-GoldSa Yöntemi ile Göğüs kanseri görüntülerinden elde edilen SSIM değerleri	151
Ek- 11: Göğüs kanseri görüntülerinden elde edilen FSIM değerleri.....	152
Ek- 12: Göğüs kanseri görüntülerinden elde edilen PSNR değerleri	153

SİMGELER

dr_t	: Sinüs fonksiyonunun genliği
τ	: Altın oran
F_c	: Frekans
t	: Number of the current iteration
t_{max}	: Maksimum iterasyon sayısı
x_1 ve x_2	: Altın kesit yönteminden elde edilen katsayılar
X_i^{t+1}	: Şuanki çözüm
X_i^t	: Gelecekteki çözüm
$best_{i,j}$	: Tüm çözümler içindeki en iyi aday
$worst_{i,j}$	: Tüm çözümler içindeki en kötü aday
$v_{ij}(k)$	: Kuşların hızları
$x_{ij}(k)$	: Kuşların pozisyonları
$P_{best,ij}$	: i^{nci} kuşun o ana kadar ki en iyi değeri (local optimum)
$g_{best,ij}$	: Tüm çözümlerin en iyisi (global optimum)
$fgbest$	: global optimumun uygunluk değeri
C_1 ve C_2	: Hızlandırma faktörleri,
$rand_1$ ve $rand_2$	: (0,1) aralığında rastgele değerler
$r1$ ve $r2$	: (0,1) aralığında rastgele değerler
$Iter$	: Şu anki iterasyon
D_p	: Gözlem havuzu
$gold$	: Altın oran değeri
eps	: Belirlenen epsilon değeri
z_t	: Kaotik haritalar elde edilen kaotik değer
μ	: Pozitif sabit kontrol parametresi (lojistik harita)
T_m^*	: m^{nci} optimal eşik değeri
S_{m+1}	: $(m+1)^{nci}$ sınıf
N	: Populasyondaki parçacık sayısı
L	: Gri seviye değeri
$Schannel$	: Optimal kanal kümesi
$Nchannel$	: Optimal kanal kümesi sayısı
$NGbest_channel$	: Optimal kanal numaraları
$Number_rhythm$	: Ritim sayısı
$best_rhythm$	: optimal ritim
Nch	: Seçilen kanal sayısı
$D(.)$	: Yön vektörü
$VisitTable$	: Ziyaret tablosu
Dim	: Boyut
$Feats$	: Özellikler
TF	: Hedef İndeks

KISALTMALAR

2DYOH-PSO	: 2d yerel olmayan ortalamalar histogramı ve PSO
AD	: Ortalama Fark (Average Difference)
BCI	: Beyin-bilgisayar arayüzü
BDE	: Sınır yer değiştirme hatası (Boundary Displacement Error)
BFO	: Bakteri Yiyecek Arama Algoritması (Bacteria Foraging Optimization)
BIDC	: Göğüs Invasiv Ductal Carcinom (Breast Invasive Ductal Carcinoma)
BiLSTM	: Çift Yönlü-Uzun-Kısa Süreli Bellek (Bidirectional-Long-Short-Term Memory)
BSDS	: Berkley-Benchmark Veri Seti (Berkley-Benchmark Data Set)
CC	: Çapraz Korelasyon (Cross Correlation)
CER	: Kaotik olarak Zenginleştirilmiş Rao (Chaotically Enhanced Rao)
CNN	: Convolutional Neural Network
CoGoldSa	: Kaotik - Karşıtlık Tabanlı Goldsa (Chaotically Enhanced Opposition Based GoldSa)
DE	: Diferansiyel Gelişim (Differential Evaluation)
DEAP	: Fizyolojik Sinyalleri Kullanarak Duygu Analizi için Veritabanı
DWT	: Ayrık Dalgacık Dönüşümünü (Discrete Wavelet Transform)
EEG	: Elektroensefalogram
FSIM	: Özellik Benzerlik İndeksi (Feature Similarity Index)
GCE	: Global tutarlılık hatası (Global Consistency Error)
GLCM	: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-occurrence Matrix)
GoldSa	: Altın Sinus Algoritması (Golden Sinus Algorithm)
GSO	: Grup Arama Optimizasyonu (Group Search Optimizer)
HA-LA	: Yüksek Uyarılma-Düşük Uyarılma (HighArousal-LowArousal)
HHO	: Harris Şahinleri Optimizasyonu (Harris Hawks Optimizer)
HS	: Uyum Arama (Harmony Search) Optimizasyonu
HV-LV	: Yüksek Değerlikli-Düşük Değerlikli (HighValence-LowValence)
ISIC	: Uluslararası Cilt Görüntüleme İşbirliği (International Skin Imaging Collaboration)
kNN	: k-en yakın komşu (K-Nearest Neighbor)
MD	: Maksimum fark (Maximum Difference)
MFO	: Güve Alevi Optimizasyonu (Moth Flame Optimization)
MVO	: Çoklu-Evren Optimizasyonu (Multi-Verse Optimization)
NAE	: Normalleştirilmiş mutlak hata (Normalized Absolute Error)
NN	: Sinir Ağı (Neural Network)
PRI	: Olasılık rand endeksi (Probability Rand Index)
PSNR	: Tepe sinyal gürültü oranı (Peak Signal to Noise Ratio)
PSO	: Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)
PS-VTS	: Ziyaret Tablosu Stratejisine dayalı Parçacık Sürü Algoritması
RMSE	: Hatanın Ortalama Karekökü (Root Mean Squared Error)
SEED	: SJTU Duygu EEG Veri seti (SJTU Emotion EEG Dataset)
SSIM	: Yapısal benzerlik indeksi (Structural Similarity)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
TLBO	: Öğretme öğrenme temelli optimizasyon (Teaching Learning Based Optimization)
TS	: Tabu Arama (Taboo Search)
VOI	: Bilgi varyasyonu (Variance of Information)
WOA	: Balina Optimizasyon Algoritması (Whale Optimization Algorithm)

1. GİRİŞ

Bu bölümde, tez çalışması kapdamında literatür incelemesi çok seviyeli görüntü eşikleme ve EEG sinyallerinden duygu tanımlama olarak iki başlık altında incelenmiştir. Ayrıca tezin amacı, literatüre katkıları ve organizasyonu alt başlıklar halinde bu bölümde sunulmuştur.

1.1. Literatür İncelemesi

Bu tez çalışmasındaki literatür incelemesi, geliştirilen yöntemlerle ilgili konu başlıkları ile bağlantılı olarak çok seviyeli görüntü eşikleme, EEG sinyallerinden duygu tanımlama ve optimizasyon algoritmaları şeklinde üç başlık altında yapılmıştır.

1.1.1. Çok Seviyeli Görüntü Eşikleme

Görüntü bölütleme, bir görüntünün yoğunluk, doku ve kontrast gibi özelliklerine dayalı olarak sınıflara ayrıldığı görüntü işleme ve örüntü tanımanın zorlu ve önemli bir adımıdır. Eşikleme ise görüntü bölütleme yöntemlerinin en basit ve en popüler metodolojilerinden biridir. Bu nedenle, kızılotesi görüntüleme [1], tıbbi görüntüleme [2], mikroskobik görüntüleme [3], uzaktan algılama [4] vb. gibi çok çeşitli alanlarda kapsamlı uygulamalara sahip olan bir yöntemdir. Eşikleme yöntemleri eşik sayısına göre iki seviyeli (bi-level) ve çok seviyeli (multi-level) eşikleme olarak iki gruba ayrılır. İki seviyeli eşikleme, bir eşik değeri kullanarak görüntüyü nesne ve arka plan olarak ikiye ayıran en temel yöntemdir. Çok seviyeli eşikleme ise ikiden fazla eşik değeri kullanarak görüntüyü birden çok sınıfa ayırmaktadır. 2014 yılında, yapılan çalışmada Otsu'nun maksimum varyansı ve Kapur entropisi yöntemleri kullanılarak çok seviyeli bir eşikleme işlemi gerçekleştirilmiştir [5]. Intel i7-4770 K CPU kullanılarak yapılan çalışmada, Otsu'nun eşikleme yönteminin yedi eşik bulması için yaklaşık iki ay, sekiz eşik için 40 yıl ve dokuz eşik için yaklaşık 10.000 yıl gerektiği belirtilmiştir.

Literatürde en sık kullanılan eşikleme amaç fonksiyonları Renyi'nin ve Kapur'un entropi yaklaşımı ile Otsu'nun sınıflar arası varyans tekniği olmuştur. Yıllar boyunca, çeşitli uygulamalar için birçok eşikleme tekniği önerilmiştir. Kapur ve diğerleri tarafından önerilen entropi yöntemi [6], bölütlenen sınıflar arasındaki benzerliği ölçmek için entropinin maksimize edilmesi ile en uygun eşik değerleri bulmak için kullanılır. Otsu' nun yönteminde [7] en uygun eşik değerleri gri seviyelerin sınıflar arası varyansını maksimize ederek bulunmaktadır. Çok seviyeli eşik problemlerinde de Kapur ve Otsu' nun yöntemleri kolayca uygulanabilmektedir. Ancak hesaplama sürelerinin çok fazla artması nedeniyle en uygun eşikleri belirlemede tek başına bu yöntemler yetersiz kalmaktadır. Çok seviyeli eşiklemede eşik sayısı ne kadar artarsa hesaplama süresi de o oranda artacaktır. Hesaplama verimliliğini artırmak için çok seviyeli eşikleme için literatürde

birçok yöntem önerilmiştir. Bu yöntemler, geleneksel Kapur ve Otsu yöntemleri ile karşılaştırıldığında çok seviyeli eşikleri belirlemedeki hesaplama karmaşıklığını büyük ölçüde azaltmaktadırlar. Metasezgisel algoritmalar, çeşitli problemlere en etkili çözümleri elde etmek amacıyla birçok alanda yaygın olarak uygulanmaktadır. Bu alanlardan bazıları; görüntü işleme [8], [9], kontrol teknikleri [10], derin öğrenme modelleri [11], [12], makine öğrenme algoritmaları [13], optimal filtre tasarımı [14], metin kümeleme [15], özellik seçimi [16] vb. Görüntü bölütlemeye, çok seviyeli eşikleme için meta-sezgisel algoritmalar yaygın olarak uygulanır. Geleneksel eşikleme segmentasyonu yaklaşımlarını kullanmanın hesaplama karmaşıklığı, eşikleme düzeylerinin sayısı ile birlikte katlanarak artar, bu durum da yöntemlerin uygulanabilirliğini sınırlı bir eşikleme düzeyi kümesiyle sınırlar. Yazarlar, bu zorluğun üstesinden gelmek amacıyla geleneksel tekniklere alternatif olarak meta-sezgisel algoritmalar tabanlı çok düzeyli eşikleme yöntemlerini kullanmaya yönelmişlerdir. Bununla birlikte, çok seviyeli eşikleme problemindeki eşik sayısının artması ile işlem karmaşıklığının artması durumu, meta-sezgisel yaklaşımların performans değerlendirmeleri için de oldukça etkili bir uygulama alanıdır. Bu açıdan bakıldığında, çok düzeyli eşikleme problemi pek çok çalışma da, önerilen metasezgisel algoritmaların etkinliğini belirlemek için test fonksiyonlarından sonra en yaygın olarak kullanılan problemlerden biri haline gelmiştir. Bu çalışmalardan bazıları incelenmiştir ve aşağıdaki paragraflarda bu çalışmalar hakkında kısa bilgiler verilmiştir.

Manikandan ve diğerleri Kapur' un entropi yöntemine dayalı çok seviyeli eşiklemeyi, simüle edilmiş ikili çaprazlama (Simulated Binary Crossover-SBX) ile kodlanmış genetik algoritma kullanılarak gerçekleştirmişlerdir [17]. Algoritma, manyetik rezonans beyin görüntülerinin bölütlenmesi amacıyla uygulanmıştır. Bulunan sonuçlar, Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO), bakteriyel yemleme optimizasyonu (Bacterial Foraging Optimization-BFO) ve uyarlamalı bakteriyel yemleme optimizasyonu (Adaptive Bacterial Foraging Optimization-ABFO) algoritmaları ile karşılaştırılmıştır ve genetik algoritmanın PSO, BF ve ABF optimizasyon yöntemlerinden daha iyi olduğu gösterilmiştir. Kurban ve ark. denge optimizasyonu (Equilibrium Optimization-EO), balçık küfü optimizasyonu (Slime Mould Algorithm-SMA), suyun türbülanslı akışı tabanlı optimizasyon algoritması (Turbulent Flow of Water-Based Optimization-TFWO), Henry gaz çözünürlüğü optimizasyonu (Henry Gas Solubility Optimizasyonu-HGSO), deniz yırtıcısı algoritması (Marine Predators Algorithm-MPA) ve politik optimizasyon (Political Optimizer-PO), algoritmasından oluşan altı ileri teknoloji meta-sezgisel algoritmayı kullanarak çok seviyeli bir renkli eşikleme segmentasyonu gerçekleştirmişlerdir [18]. Sonuçlar, referans görüntü tabanlı indeksler ve referanssız görüntü kalitesi ölçüm indeksleri açısından değerlendirilmiştir. Deneysel çalışmalarda drone ile havadan çekilen test görüntüleri kullanılmıştır. Kapur'un entropisi ve Otsu'nun varyansı metasezgisel algoritmaların amaç fonksiyonları olarak kullanılmıştır. Yazarlar yaptıkları bir takım deneysel analizler sonucunda,

MPA ve TFWO'nun, çok seviyeli renkli hava görüntülerinin eşiklenmesinde SMA, EO, PO ve HGSO'dan daha iyi performans gösterdiğini belirtmişlerdir. Bir başka çalışmada, uydu görüntülerinin çok seviyeli eşiklenmesi için Denge-Cuckoo Arama Optimize Edici (ECSO) adıyla hibritleştirilmiş bir optimizasyon algoritması önerilmiştir [19]. Ayrıca bu çalışmada, logaritmik fonksiyonu kullandığı için bazı dezavantajlara sahip olan geleneksel entropinin yerine diferansiyel üstel entropi (DEE) tabanlı çok düzeyli bir eşikleme yöntemi geliştirilmiştir. Standart kıyaslama fonksiyonları analizlerde kullanılmıştır. Sonuçlar, fizik tabanlı Denge Optimize Edici (EO) ve doğadan ilham alan Cuckoo Arama Algoritması (CSA) ile karşılaştırılmıştır. Landsat Image Gallery veri tabanından renkli uydu görüntüleri elde edilerek deneysel çalışmalar bu görüntüler üzerinde gerçekleştirilmiştir. Görüntü kalitesi değerlendirmesi için PSNR, SSIM ve FSIM gibi indeksler kullanılmıştır. Elde edilen deneysel sonuçlar ile önerilen yöntemin diğer tekniklerden daha iyi performans gösterdiği belirtilmiştir.

Agrawal ve ark., mercan resifi optimizasyon algoritmasına dayalı çok seviyeli bir eşikleme yöntemi geliştirmiştir [20]. Yazarlar, köşegen sınıf entropisinden elde edilen amaç fonksiyonunu minimize ederek optimum eşik değerlerini bulmuşlardır. Önerilen yöntem, 2-D Otsu'nun yöntemi ve diğer çok seviyeli eşikleme yöntemleri (Kapur'un Entropisi [6], Saliency Haritası [21], K-L farklılığı ile değiştirilmiş parçacık sürü optimizasyon yöntemi [22] ve Entropi-tabanlı yöntemi [23]) ile karşılaştırılmıştır. Yöntemin üstünlüğü daha sonra deneysel sonuçlarla gösterilmiştir. Pare ve ark. tarafından gri seviye eş oluşum matrisine (Gray Level Co-occurrence Matrix-GLCM) dayalı renkli çok seviyeli eşikleme için yeni bir segmentasyon yaklaşımı sunulmuştur [24]. Hesaplama karmaşıklığı ve kararlılıkla ilgili GLCM'nin eksikliklerini gidermek ve optimum eşik değerlerini bulmak amacıyla Diferansiyel Gelişim (Differential Evolution-DE) algoritması kullanılmıştır. Geliştirilen yaklaşımın diğer yöntemlere (Geriye Yayılım Arama Optimizasyonu, Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO), Bakteri Yiyecek Arama Algoritması (Bacteria Foraging Optimization-BFO) ve geleneksel GLCM yöntemi) göre daha iyi performans gösterdiği belirtilmiştir. Ayrıca, kapsamlı enerji işlevini kullanan renkli çok seviyeli görüntü bölütleme için sürü tabanlı bir algoritma Pare ve ark. tarafından uygulanmıştır [25]. Shao ve ark. farklı bir arama algoritmasına dayalı çok seviyeli eşikleme kullanarak ultrason görüntülerini bölütlemek için yeni bir yöntem önermişlerdir [26]. Bhandari ve ark. uydu görüntülerini Kapur'un entropisine dayalı çok seviyeli eşikleme yöntemi ile bölütlemek için guguk kuşu ve rüzgar gücü optimizasyon algoritmasını kullanmışlardır [27]. Bao ve ark. çok seviyeli renkli görüntü bölütleme için Harris Şahinleri Optimizasyonu (Harris Hawks Optimizer-HHO) ve DE optimizasyon algoritmalarını birleştiren yeni bir hibrit algoritma önermişlerdir [28]. Jia ve ark. renkli görüntü bölütleme performansını iyileştirmek için kendinden uyarlamalı güve alevi optimizasyonu (Moth Flame Optimization-MFO) adı verilen yeni bir algoritma geliştirmişlerdir [29]. Amaç fonksiyonu olarak Kapur'un entropi yöntemi ve Otsu'nun eşikleme yöntemi kullanılmıştır. Sonuçlar diğer sekiz meta-

sezgisel algoritma (Çoklu-Evren Optimizasyonu (Multi-Verse Optimization-MVO), Balina Optimizasyon Algoritması (Whale Optimization Algorithm-WOA), orijinal MFO algoritması vb.) ile karşılaştırılmıştır. Önerilen optimizasyon algoritmasının diğer algoritmalarından daha iyi olduğu makalede bildirilmiştir. Pare ve ark., farklı seviyelerde renkli görüntülerin çok seviyeli eşiklenmesini gerçekleştirmek amacıyla değiştirilmiş bir bulanık entropi fonksiyonu sunmuşlardır [30]. Levy uçuş güdümlü ateş böceği algoritması kullanılarak arama performansı ve görüntü bölütleme performansı iyileştirilmiştir. Bunların dışında, Diferansiyel Evrimsel Uyarlanabilir HH Optimizasyon Algoritması [31], geliştirilmiş imparator penguen optimizasyon algoritması [32], genetik çaprazlama işlemi ve akıllı atalet ağırlığı ile değiştirilmiş hibrit yarası algoritması [33], uyum arama algoritması [34], yıldırım arama algoritması [35], karga arama algoritması [36], [37], kril sürüsü algoritması [38], Grunwald–Letnikov tabanlı manta ışını yiyecek arama optimizasyonu [39], öğrenme coşkısına dayalı öğretme-öğrenmeye dayalı optimizasyon algoritması [40] çok seviyeli eşikleme için geliştirilerek uygulanmıştır.

Literatürde birçok histogram tabanlı yöntem önerilmiştir. Bunlardan biri tek-boyutlu histogram yöntemleridir. Ancak bu yöntemler, vadiler, zirveler gibi histogram bilgilerini kullanırken mekansal bilgiyi dikkate almamıştır. Bu da farklı özelliklere sahip görüntülerin aynı histograma sahip olmasına yol açar. Dolayısıyla, benzer eşik değerleriyle bölütlenirler ki bu da uygun değildir. Bu sorunu çözmek için, pikseller arasındaki mekansal bilgiyi kullanarak görüntü eşikleme performansını artırmak amacıyla iki boyutlu histogramlar; gri seviye mekansal korelasyon (Gray-Level Spatial Correlation -GLSC) histogramı [41], iki boyutlu yönlendirme histogramı [42], gri seviye gradyan büyüklüğü (Gray Level-Gradient Magnitude-GLGM) histogramı [43], gri seviye yerel entropi (Gray Level-Local Entropy-GLLE) histogramı, gri seviye yerel varyans (Gray Level-Local Variance-GLLV) histogramı [44] ve Gabor histogramı [45] gibi yöntemler önerilmiştir. Mittal ve Saraswat, iki boyutlu, histogram tabanlı, yeni birçok seviyeli eşikleme yöntemi geliştirmişlerdir [46]. Bu yöntemde, optimum eşik değerleri belirlemek için Üstel Yerçekimi Arama Algoritması (exponenotional Kbest GSA-eKGSA) kullanılmıştır. Deneylerinde, BSDS300 veri seti üzerinde 3 ve 5 seviyeli görüntü segmentasyonları yapılmıştır. Önerilen yöntemin performans analizi için 12 farklı ölçüm kullanılmıştır. Deneysel sonuçlar, ABC, Yerçekimi Arama Algoritması (Gravitational Search Algorithm-GSA), Kaotik Kbest Yerçekimi Arama Algoritması (chaotic Kbest GSA-cKGSA) ve DE yöntemleriyle karşılaştırılarak verilmiştir. [47]'de Otsu'nun maksimum varyansı esas alınarak ABC ve Sinüs-Kosinüs Algoritmasını kullanan hibrit bir yöntem önerilmiştir. PSNR ve SSIM ölçüm indeksleri açısından diğer altı algoritmayla karşılaştırmalı olarak değerlendirilmiştir. Deneysel sonuçlar, önerilen yöntemin PSNR ve SSIM değerlerinde diğer yöntemlere göre sırasıyla %41 ve %39 daha iyi performans gösterdiği belirtilmiştir. Başka bir çalışmada, renkli görüntüleri [48] bölümlere ayırmak için çoklu evren teorisine dayalı yeni bir optimizasyon stratejisi sunulmuştur; test için sekiz görüntü kullanılmıştır

ve görüntüler farklı eşik seviyelerinde (5, 8, 11 düzeyleri) bölütlenmiştir. Önerilen yöntem PSNR, SSIM ve FSIM değerlendirme indeksleri ile değerlendirilmiş olup önerilen yöntemin Paralel Parçacık Sürü Optimizasyonu ve Gri Kurt Optimizasyonu algoritmalarından daha iyi sonuçlar ürettiği sonucuna varılmıştır. Günümüzde mevcut olan birçok çalışma, çok seviyeli eşikleme ile ilişkilendirilmiştir [49], [50], [51], [52], [53], [54]. Bu çalışmalarda, çeşitli alanlardaki uygulamalar için farklı yöntemler kullanılarak daha doğru görüntü bölütlemenin sağlanması amaçlanmıştır.

Cilt kanseri (SC), ırk, cinsiyet veya yaştan bağımsız olarak herkesi etkileyebilen ciddi ve yaygın bir hastalıktır. Malign cilt kanseri türlerinden biridir ve en yaygın ve ölümcül tür olarak kabul edilir [55]. Malign melanomun erken tanısı, mortalite oranını önemli ölçüde azaltabilir ve tedavi maliyetlerini azaltabilir. Bu, önerilen yaklaşımların kanser türlerinin belirlenmesinde daha doğru ve etkin kullanılması ve bu yaklaşımların performansının artırılmasıyla sağlanabilir. Bu, araştırmacıları yeni teknikler geliştirmeye ve mevcut tekniklerin performansını artırmaya teşvik eder. Görüntü bölütleme, kanser türünün erken teşhisinde, tıbbi uygulamalarda, cerrahi uygulamalarda vb. uygulamalarda görüntü işlemenin en kritik adımlarından biridir. Araştırmacılar meta-sezgisel algoritmalar kullanarak cilt kanseri görüntülerinin çok seviyeli eşiklemesini gerçekleştirmişlerdir [55], [56], [57]. Bölütlenmiş görüntü genellikle daha iyi değerlendirme için işlem sonrası adımda kullanılabilir. Otsu'nun maksimum varyansını kullanarak çok seviyeli eşikleme problemini çözmek için altın çakal optimizasyon algoritmasının geliştirilmiş bir versiyonu kullanılmıştır [55]. Ren ve diğerleri tarafından değiştirilmiş bir diferansiyel evrim optimizasyon algoritması önerilmiştir [56]. Bu optimizasyon algoritması, beyaz deliklerin, kara deliklerin ve solucan deliklerinin hareket mekanizmalarının çeşitli evrimlere dahil edilmesiyle geliştirilmiştir. Geliştirilen algoritmanın performansı 30 kıyaslama fonksiyonu üzerinde sınanmıştır. Ayrıca önerilen algoritmaya dayalı etkin bir görüntü eşikleme çerçevesi sunulmuştur. Eşikleme yaklaşımı, yüksek kaliteli segmentasyon sonuçları sağladığı deneysel çalışmalarla gösterilmiştir. Ek olarak, geliştirilen segmentasyon yöntemi, meme kanseri ve cilt kanseri patoloji görüntülerine uygulanarak diğer yöntemlerle karşılaştırmalar yapılmıştır. Önerilen optimizasyon algoritması tabanlı bölütleme yaklaşımının birçok performans değerlendirme indeksi açısından iyi bir performans sergilediği deneysel olarak gösterilmiştir. Zhu ve diğerleri. Kaotik rastgele mutasyon stratejisi ve Levy operatörü ile Balina Optimizasyon Algoritmasının etkili bir versiyonunu geliştirdiler. Geliştirilen yöntem ile deri kanseri görüntülerinin bölütlenmesinde kullanılarak etkili sonuçlar elde edilmiştir [57].

Cilt kanseri görüntülerinin yanı sıra çeşitli tıbbi görüntülerin bölütlenmesinde metasezgisel yöntemlerden de faydalanılmaktadır. Tıbbi görüntü segmentasyonu, Hosny ve ark. tarafından MRI, CT ve X-ışını gibi farklı yöntemlerden alınan 2D ve 3D tıbbi görüntüler kullanılarak gerçekleştirilmiştir. [58]. Jena ve ark. Manta Ray'e saldıran yiyecek arama optimizasyonu adı verilen yeni bir meta-sezgisel algoritma önermiştir [59]. Bununla birlikte, MR görüntülerinin çok

seviyeli eşikleme segmentasyonu için objektif bir fonksiyon olarak maksimum 3D Tsallis entropisini önermişlerdir. Çok seviyeli eşikleme segmentasyonu için değiştirilmiş bir balçık kalıbı algoritması önerilmiştir [60]. Geliştirilen algoritmaya dayalı Lupus Nefrit görüntülerinin bölütlenmesi uygulamasında oldukça başarılı olduğu deneysel çalışmalar ile göstermiştir.

1.1.2. EEG Sinyallerinden Duygu Tanımlama

İnsan beyni, kişilerarası iletişim için gerekli olan psikolojik ve fizyolojik bir durum olan insan duygusunu üretir [61]. İnsanlar boş bir sayfa ile düşünmeye başlamazlar. Duygular, günlük karar verme ve fizyolojik süreçlerde esastır [62]. Beyinden alınan elektroensefalogram (EEG) verileri, duygusal durumdaki bir değişiklik ile bağlantılı bilgileri tanımlayabilir, çünkü beyin aktivitesi duygu yaratma ve eylem için çok önemlidir. Beyin-bilgisayar arayüzünün (BCI) ilerlemesinin, yapay zeka [63] ve duygu tanıma [64], [65], [66], [67] çalışmaları için önemli etkileri vardır. Eğlence ve oyun, eğitim, adli soruşturma, yardımcı sürüş, sağlık hizmetleri ve diğer disiplinlerde, EEG verilerine dayalı duygu tanımlama çok çeşitli potansiyel uygulamalar sunmaktadır [68]. İlgili yayınlar incelendiğinde, yazarların öncelikle insan duygularını tanımlamak için tüm EEG verilerini kullanmaya odaklandıkları ortaya çıkmıştır. Duygu tanıma için evrişimli sinir ağı (Convolutional Neural Network-CNN) tabanlı modeller EEG sinyallerinden özellikleri çıkarmak için Demir ve arkadaşları tarafından kullanılmıştır [69]. Fizyolojik Sinyalleri Kullanarak Duygu Analizi için Veritabanı (Database for Emotion Analysis using Physiological Signals-DEAP) veri seti kullanılarak %98.93 doğruluk elde edilmiştir. Tuncer ve ark., EEG tabanlı duygu kategorizasyonu için Tetromino özelliklerini ve bir destek vektör makinesi (Support Vector Machine-SVM) sınıflandırıcısını kullanmıştır [70]. Bu çalışmada, ayrık dalgacık dönüşümünü (Discrete Wavelet Transform-DWT) kullanarak, EEG sinyalleri ritimlere bölünmüş ve her ritimden tetromino özellikleri alınmıştır. Dreamer, Gameemo ve DEAP veri setleri için sırasıyla %100, %100 ve %99 sınıflandırma doğruluğu elde edilmiştir. Ismael ve diğerleri tarafından EEG tabanlı duygu sınıflandırması için iki aşamalı bir yaklaşım kullanılmıştır [71]. Yazarlar başlangıçta EEG sinyalinde gürültü giderme için düşük geçişli filtreleme uygulamışlardır ve EEG ritimleri, bant geçiren filtreleme kullanılarak çıkarılmıştır. Yazarlar, özellik çıkarımı için dalgacık entropisi ve fraktal boyut yöntemlerini kullanmışlardır ve çıkarılan öznitelikler, her ritim için en iyi performans gösteren EEG kanallarını belirlemek için k-en yakın komşu (K-Nearest Neighbor-kNN) sınıflandırıcısı kullanılarak sınıflandırılmıştır. Her bir EEG ritmi için nihai sonuç daha sonra ilk beş EEG kanalı dikkate alınarak çoğunluk oyu ile belirlenmiştir. Deneyler DEAP veri seti üzerinde gerçekleştirilmiş ve yüksek değerlikli-düşük değerlikli (HighValence-LowValence(HV-LV)) sınıflandırması için %86.3 ve Yüksek Uyarılma-Düşük Uyarılma (HighArousal-LowArousal(HA-LA)) sınıflandırması için %85.0 doğruluk elde edilmiştir. Joshi ve arkadaşları tarafından EEG tabanlı duygu tanıma için bir paradigma sunulmuştur [72]. Burada diferansiyel entropi ve çift

yönlü-uzun-kısa süreli bellek (Bidirectional-Long-Short-Term Memory-BiLSTM) yöntemi yaklaşımları kullanılmıştır. SJTU Duygu EEG Veri seti (SJTU Emotion EEG Dataset – SEED) ve DEAP veri kümeleri için sırasıyla %80.64 ve %76.75 doğruluk bildirilmiştir. EEG verilerinden duyguları tanımak için Gao ve ark. [73], mekansal ve zamansal sinir ağı (Neural Network-NN) mimarisine dayalı yeni bir füzyon sinir ağı geliştirmişlerdir. Zaman ve frekans alanlarındaki özelliklerin her ikisi de gözününde bulundurulmuştur. Ek olarak, yazarlar EEG elektrotları ve bağlamsal veriler arasındaki doğal uzamsal bağlantıyı yakalamak için bir CNN modeli oluşturmuşlardır. Deneysel çalışmalarda DEAP veri seti üzerinde değerlik ve uyarılma sınıfları için sırasıyla %80.52 ve %75.22 sınıflandırma doğruluğu rapor edilmiştir. Xing ve diğerleri tarafından bir duygu tanıma modeli oluşturmak için doğrusal bir EEG modeli ve duygu zamanlama modelleri kullanılmıştır [74]. DEAP veri setini kullanan yazarlar, değerlik sınıfı için %81.10 ve uyarılma sınıfı için %74.38'lik bir doğruluk elde edebilmişlerdir. Şengur ve ark., insan duygularının algılanmasını sağlamak için sürekli dalgacık dönüşümü ve derin öznitelikleri kullanmışlardır [75]. Bahsedilen yöntemi EEG sinyalinin her bir ritmine uygulamışlar ve duygu tanıma için en etkili ritmi gözlemlemişlerdir. Bu prosedür manuel olarak gerçekleştirilmiş ve herhangi bir optimizasyon algoritması dahil edilmemiştir. Değerlik ve uyarılma sınıfları için sırasıyla %96.1 ve %99.6 doğruluk elde edilmiştir.

Çeşitli EEG tabanlı uygulamalarda EEG kanal seçimi için metasezgisel yaklaşımlar önerilmiştir. Mandal ve ark. tarafından hayali motor uygulamalarında en uygun kanalları seçmek amacıyla bir hibrit optimizasyon yaklaşımı kullanılmıştır [76]. Daha spesifik olarak, geometrik ortalamaya dayalı MFO ve ateş böceği algoritmaları kullanılarak hibrit bir yapı geliştirilmiştir. Alyasseri ve ark. verimli kullanıcı tanımlaması için çiçek tozlaşma optimize edicinin verimli bir versiyonunu sunmuşlardır [77]. Önerilen yöntem EEG sinyallerinin kanal seçimine uygulanmıştır. Geliştirilen optimizasyon yöntemi, β tepe tırmanma yöntemi ile çiçek tozlaşmasının geliştirilmiş bir versiyonudur. Geliştirilen yöntemin etkinliğini değerlendirmek için yaygın bir EEG veri seti kullanılmıştır. Hussien ve ark. beyin-bilgisayar arayüzlerinde kullanılacak optimum EEG kanallarını seçebilen, önemli ve alakasız karakterleri tanımlayabilen geliştirilmiş bir gri kurt optimizasyonu önermişlerdir [78].

1.1.3. Optimizasyon Algoritmaları

Optimizasyon; bir sistemin veya sürecin, belirli bir amacı en iyi şekilde gerçekleştirmek için en uygun çözümünü bulma sürecidir. Bu amaç, maliyeti minimize etmek, karı maksimize etmek, verimliliği artırmak olabilir. Optimizasyon problemleri geniş bir alana yayılmıştır ve birçok farklı disiplinde çalışan araştırmacıların ilgisini çekmektedir. Bu alandaki problemler için etkin çözümler üretebilmektedir. Kontrol sistemleri [10], enerji [79], aerodinamik [80], görüntü işleme [81], makine öğrenmesi [82], derin öğrenme [83] gibi alanlarda optimizasyon önemli bir konudur.

Optimizasyonun temel amacı, kaynakların en etkin şekilde kullanılmasını sağlamak ve belirlenen hedeflere ulaşmak için en uygun stratejileri belirlemektir. Bu nedenle, karmaşık problemleri çözmek ve rekabet avantajı elde etmek için optimizasyonun kullanımı giderek artmaktadır. Bu algoritmalar, genellikle problemin belirli özelliklerini veya kısıtlarını dikkate alarak tasarlanır. Metasezgisel algoritmalar, optimizasyon için kullanılan etkin ve yaygın kullanılan yöntemlerdir.

Metasezgisel algoritmalar, belirli bir problemi çözmek için kullanılan diğer sezgisel algoritmaların davranışını, performansını veya özelliklerini optimize etmek için tasarlanmış olan algoritmaları ifade etmektedir. ‘*metasezgisel*’ terimi ‘*metaheuristic*’ olarak 1986 yılında ortaya çıkmıştır ve Yunancadaki ‘*meta*’ ve ‘*heuristic*’ kelimelerinden türetilmiş olup ‘*daha ileri sezgisel*’ anlamına gelmektedir. Örneğin, genetik algoritma [84], PSO [85], simüle edilen tavlama [86], karınca kolonisi optimizasyonu [87] (Ant Colony Optimization-ACO) gibi algoritmaları içeren birçok metasezgisel algoritma vardır. Bu algoritmalar, doğal olaylardan veya hayvanların davranışlarından esinlenerek geliştirilmiş olabilir. Metasezgisel algoritmalar, karmaşık ve çok boyutlu problemleri çözmek için kullanılırlar. Bu algoritmalar, özellikle tüm olası çözüm uzayını aramak yerine, problemin belirli özelliklerini veya kısıtlarını dikkate alarak daha etkili bir şekilde arama yapabilirler. Bu nedenle, genellikle karmaşık optimizasyon problemlerinde, yapay zeka, veri madenciliği, mühendislik ve diğer birçok alanda kullanılmaktadır.

Geçmişten günümüze geliştirilmiş olan çeşitli optimizasyon yöntemleri yıllara göre bu bölümde incelenmiştir. En eski yöntemlerden bazıları DE, PSO, ACO, Yer Çekimi Arama Algoritması (Gravitational Search Algorithm-GSA), Yapay Arı Koloni (Artificial Bee Colony-ABC) algoritmasıdır. DE algoritması, Darwin'in evrim teorisinden esinlenen popüler bir evrimsel algoritmadır [88]. Storn tarafından 1997 yılında optimizasyon ve mühendislik uygulamalarındaki problemleri çözmek amacıyla geliştirmiştir. PSO, sürü halinde yaşayan canlıların davranışlarından esinlenilerek geliştirilmiş sezgisel bir yöntemdir [85]. 1995 yılında Kennedy ve Ebberhart tarafından geliştirilmiş olup yerel ve küresel çözümlere dayalı olarak parçacıkların pozisyonları her iterasyonda güncellenmektedir. ACO, karıncaların yiyecek arama davranışlarından esinlenerek geliştirilmiş bir yöntemdir [87]. 2006 yılında Dorigo ve ark. tarafından küresel optimizasyon problemlerini çözmek için karıncaların yuvaları ile besin kaynakları arasında kısa yollar bulmalarını sağlayan kimyasal feromon izleri yardımıyla aralarındaki dolaylı iletişime dayalı olarak geliştirilmiştir. GSA ise Newton'un yerçekimi ve hareket yasalarına dayalı olarak birbirleriyle etkileşime giren kütlelere dayalı olarak geliştirilmiştir bir yöntemdir [89]. Rashidi ve ark. tarafından 2009 yılında önerilmiştir. ABC, arıların yiyecek arama davranışından esinlenerek geliştirilmiş evrimsel bir yaklaşımdır [90]. Bu yöntemde; görevli arılar, işsiz toplayıcı arılar ile yiyecek kaynakları şeklinde üç bileşen bulunmaktadır. Son yıllarda önerilen algoritmalarından bazıları; Altın Çakal Optimizasyonu (Golden Jackal Optimization-GJO), Bal Porsuğu Algoritması (Honey Badger Algorithm-HBA), Kaya Kartalı Optimizasyonu (Aquila Optimizer-AO), Atomik

Orbital Arama (Atomic Orbital Search-AOS), (Elephant Clan Optimization-ECO), Su Böceği Algoritması (Water Strider Algorithm-WSO), Fındıkkıran Optimizasyon Algoritması (Nutcracker Optimization Algorithm-NOA), Ceylan Optimizasyon Algoritması (Gazzele Optimization Algorithm-GOA).

GJO, Chopra ve Ensari tarafından 2022 yılında doğadan ilham alınarak geliştirilen bir yöntemdir [91]. Canis aureus olarak adlandırılan altın çakalların avlanma davranışları modellenerek oluşturulmuştur. Avı arama, kuşatma ve saldırma olarak üç adımda optimizasyon sürecini tamamlamaktadır. HBA, Haşim ve ark. tarafından 2022 yılında optimizasyon problemlerini çözmek amacıyla geliştirilen bir yöntemdir [92]. Bal porsuğunun kazma ve bal bulma davranışları modellenerek oluşturulmuş olup bu davranışları keşif ve sömürü aşamaları halinde formülize edilmiştir. AO, kaya kartalının avını avlama davranışından ilham alınarak geliştirilen popülasyon temelli bir yöntemdir [93]. 2021 yılında Abualigah ve ark. tarafından geliştirilen bu yöntem, dikey eğimle yüksekten uçuşa, direkt yaklaşma uçuşu, yavaş alçalma saldırısıyla alçak uçuş ve yürüyerek saldırıp avı yakalama davranışlarını dört adımda modelleyerek optimizasyon sürecini tamamlamaktadır. AOS, Azizi tarafından 2021 yılında önerilen bu yöntem, optimizasyon problemlerini çözmek amacıyla yeni bir metasezgisel algoritma olarak sunulmuştur [94]. Yöntemde, kuantum mekaniğinin temel prensipleri, kuantum-tabanlı atom modeli ve elektronların çekirdek etrafındaki davranışları modellenerek oluşturulmuştur. ECO yöntemi fillerin sürü halindeki davranışlarını modelleyen 2021 yılında Caferi ve ark. tarafından geliştirilmiş bir yöntemdir [95]. Bu yöntemde, reisin yönlendirme davranışı, fillerin sağlam hafıza yapıları ve deneyimlerine dayalı yiyecek arama davranışları incelenerek oluşturulmuştur. WSO, su böceklerinin yaşam döngüsünden esinlenerek geliştirilmiştir [96]. Kaveh ve ark. tarafından 2020 yılında geliştirilen bu yöntem, su böceklerinin iletişimi, çiftleşmesi, beslenmesi, yürüyüşleri ve bölgesel davranışları incelenerek fomülize edilmiştir. NOA, fındıkkıranların arama ve kurtarma davranışları ile hafıza yapıları incelenerek geliştirilmiş olup Abdel-Basset ve ark. tarafından 2023 yılında önerilmiştir [97]. Davranışlar, yaz-sonbahar ve ilkbahar-kış olarak iki kısımda ele alınmıştır. Bu dönemlerden, yaz-sonbaharda; tohumların aranması ve toplanan tohumların saklanması, ilkbahar-kış döneminde ise çeşitli işaretçileri referans kabul edip onların etrafında saklanmış olan yiyecekleri arama şeklindedir. GOA, Agushaka ve ark. tarafından 2023 yılında önerilmiştir [98]. Avcıların çoğunlukta olduğu bölgelerde yaşayan ceylanların hayatta kalmak için yaptıkları davranışların gözlemlenerek modellenmesi ile oluşturulmuştur. Yırtıcının farkında olduğu durum ile farkında olmadığı durumdaki hareketleri olmak üzere iki aşamada incelenmiştir.

Bunlarla beraber, Sincap Arama Algoritması [99] (Squirrel Search Algorithm-SSA) 2019 yılında Jain ve ark. tarafından önerilmiş olup uçan sincapların davranışlarından esinlenerek geliştirilmiştir. Çekirge Optimizasyon Algoritması [100] (Grasshopper Optimization Algorithm-GOA); 2017 yılında Saremi ve ark. tarafından çekirgelerin sürü halindeki davranışlarından, Altın

Kartal Optimizasyonu [101] (Golden Eagle Optimizer-GEO); Mohammadi-Balani ve ark. tarafından 2021 yılında altın kartalların hızlarını ayarlamaadaki davranışlarından, Aritmetik Optimizasyon Algoritması [102] (Arithmetic Optimization Algorithm-AOA); Abualigah ve ark. tarafından 2021 yılında ana aritmetik operatörlerin dağılım yapısından, Henry Gaz Çözünürlüğü Optimizasyonu [103] (Henry Gas Solubility Optimization-HGSO); Hashim ve ark. tarafından Henry yasasından, Toplu Karar Optimizasyonu [104] (Collective Decision Optimization-CSO); Zhang ve ark. tarafından 2017 yılında insanın karar verme özelliklerinden esinlenerek, Sosyo Evrim ve Öğrenme Optimizasyon Algoritması [105] (Socio Evolution & Learning Optimization Algorithm-SELOA); Kumar ve ark. tarafından 2018 yılında insanın sosyal öğrenme davranışlarından, Voleybol Premier Ligi Algoritması [106] (Volleyball Premier League Algorithm-VPLA); Moghdani ve ark. tarafından 2018 yılında voleybol takımlarının müsabakalarından, Deniz Yırtıcıları Algoritması [107] (Marine Predators Algorithm-MPA); Faramazi ve ark. tarafından avcıların okyanuslarda yiyecek arama stratejisinden esinlenerek geliştirilmiştir.

1.2. Tezin Amacı

Bu tez çalışmasında; optimizasyon algoritmalarının, görüntü işleme ve sınıflandırma gibi alanlardaki yöntemlerin performanslarının iyileştirilmesindeki etkinliğinin gösterilmesi amaçlanmıştır. Bu kapsamda;

A) Görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik gösteren eşikleme yöntemleri çeşitli veri setleri üzerinde analiz edilerek metasezgisel yöntemlere dayalı olarak geliştirilen yaklaşımlarla performanslarının iyileştirilmesi amaçlanmıştır. Bu amaçla gerçekleştirilen çalışmalar ve katkılar özetle aşağıda verilmiştir.

Altın Sinüs Algoritmasına (Golden Sinus Algorithm-GoldSa) dayalı çok seviyeli bir eşikleme yöntemi geliştirilmiştir. GoldSa yöntemi güncel bir yöntem olup çok seviyeli eşikleme problemi üzerindeki davranışı ilk defa incelenmiştir. İki boyutlu, yerel olmayan ortalama histogram ve Renyi'nin entropisi kullanılarak farklı eşikleme seviyelerine ve farklı özelliklere sahip görüntüler bölütlenmiştir. Önerilen iki boyutlu, yerel olmayan Altın Sinüs Algoritması (Non-Local Means Golden Sinus Algorithm II - NLM-GoldSa II) bölütleme yönteminin mevcut yöntemlere göre üstün sonuçlar ürettiği gözlemlenmiştir.

Parçacık Sürü Optimizasyonuna Dayalı Çok Seviyeli Eşikleme için İki boyutlu yerel olmayan ortalamalar histogramına ve Renyi'nin entropisine dayalı çok seviyeli bir eşikleme yöntemi (2DYOH-PSO) çok fazla ayrıntıya sahip görüntülerin bölütleme performansını artırmak amacıyla önerilmiştir. Maliyet fonksiyonu olarak iki boyutlu histogram da Renyi' nin entropisi çok seviyeli eşikleme için yeniden tanımlanmıştır. Hesaplama süresini azaltarak en uygun eşik değerlerini bulmak amacıyla PSO algoritması probleme uyarlanmıştır. 2DYOH-PSO yöntemi, BSDS300 verisetindeki görüntüler için uygulanan çok seviyeli eşiklemede 12 farklı kalite ölçüm

endeksi (BDE, PRI, VOI, GCE, SSIM, FSIM, PSNR, RMSE, NAE, AD, MD) açısından oldukça başarılı olan GSA, ABC, DE, cKGSA ve eKGSA yöntemleri ile karşılaştırılarak daha etkin sonuçlar elde edildiği deneysel çalışmalar ile gösterilmiştir.

B) Çok seviyeli eşiklemede manuel olarak belirlenen eşik seviye sayısının otomatik olarak belirlenmesi amaçlanmıştır. Bu amaçla gerçekleştirilen çalışmalar ve katkılar özetle aşağıda verilmiştir.

Çok seviyeli görüntü eşikleme için uyarlanabilir, kaotik olarak geliştirilmiş bir Rao (Chaotically Enhanced Rao-CER) algoritması geliştirilmiştir. CER algoritmasına, Gri Seviye Eş Oluşum Matrisine ve Otsu'nun maksimum varyansına dayalı adaptif çok seviyeli bir görüntü segmentasyon yöntemi sunulmuştur. Her görüntü için bölütlenecek bölge sayısının ayırt edici olduğu belirlenmiştir ve literatürdeki pek çok çalışmadaki gibi veri kümesindeki tüm görüntüleri belirli bir sabit segment numarasına göre bölümlenmek yerine, veri kümesindeki her görüntü için bölütlenecek bölge sayısını otomatik olarak bulan bir yöntem geliştirilmiştir. Önerilen yöntem, yakın zamanda yayınlanan ve basit matematiksel denklemlere dayanan Rao algoritmasına dayalı olarak geliştirilmiştir. Rao algoritmasındaki düzensiz rastgelelik yerine önerilen algorithmada kaotik davranıştan yararlanılmıştır. Kaotik haritaların davranışları, Rao algoritmasının düzensiz rastgelelik sergileyen parametreleri üzerinde incelenmiştir.

C) Metasezigesel yöntemlerin görüntü eşiklemedeki etkililiğini artırmak amacıyla bu yöntemler çeşitli stratejiler ile desteklenerek iyileştirmeler yapılmıştır. Bu amaçla gerçekleştirilen çalışmalar ve katkılar özetle aşağıda verilmiştir

GoldSa yönteminin keşif ve sömürü yeteneklerinin verimliliğini artırmak için kaotik haritalarla zenginleştirilmiş karşıtlık tabanlı bir Altın Sinüs Algoritması önerilmiştir. Kaotik haritaların farklı davranışa sahip parametreler üzerindeki etkisini belirlemek için sekiz kaotik harita kullanılarak kaotik GoldSa (cGoldSa) yöntemleri geliştirilmiştir. Başlangıç popülasyonunun etkinliğini artırmak için ise karşıtlık temelli öğrenme stratejisine dayalı Co-GoldSa yöntemi geliştirilmiştir.

Sık ziyaret edilen noktalara ve bu noktaların komşularına daha az ziyaret yapılmasıyla yeni noktaların keşfedilmesine olanak tanıyarak PSO algoritmasının gereksiz aramalarını önleyen bir ziyaret tablosu stratejisi ve çok yönlü bir arama stratejisi algorithmaya entegre edilmiştir. Renyi'nin entropisi ve yerel olmayan ortalamalar 2D histogramı kullanılarak geliştirilen PS-VTS optimizasyon algoritmasına dayalı çok seviyeli bir eşikleme yöntemi önerilmiştir. Aynı zamanda çok seviyeli eşikleme görüntü bölütleme uygulamaları ve kıyaslama sorunları için iyi bilinen meta-sezgisel yaklaşımların niceliksel, niteliksel ve ölçeklenebilirlik analizleriyle ayrıntılı bir analizini sunmaktadır.

D) Ek olarak, EEG sinyallerinden duygu sınıflandırma performansı artırmak amaçlanmıştır. Bu amaçla, optimizasyon yöntemler kullanılarak yaklaşımın etkililiği artırılmış ve daha az kanalla

daha yüksek doğrulukta duygu tanımlama çalışması gerçekleştirilmiştir. Bu amaçla gerçekleştirilen çalışmalar ve katkılar özetle aşağıda verilmiştir.

EEG sinyallerinin otomatik kanal ve ritim seçimi sorununu çözmek için Ziyaret Tablosu ile Çok Yönlü Arama Stratejisi ile zenginleştirilmiş Parçacık Sürüsü (PS-VTS) Algoritmasına dayalı bir yaklaşım geliştirilmiştir. En etkili kanal ve ritim kombinasyonlarının otomatik seçimi için en uygun çerçeveler aranarak kanal ve ritim kombinasyonlarının seçimi için iki yeni çerçeve sunulmuştur. DEAP veri seti üzerinde yapılan deneyler, önerilen yaklaşımın daha az EEG kanalıyla daha yüksek doğrulukta duygu sınıflandırması gerçekleştirilmiştir.

1.3. Tezin Literatüre Katkıları

Bu tez çalışması kapsamında, 5 adet uluslararası Science Citation Index Expanded indeksli makale yayınlanmıştır [108], [109], [110], [111], [112]. 1 adet makale ise Science Citation Index Expanded indeksli dergilerde hakem değerlendirmesi aşamasındadır. Yayınlarla ilgili detaylar aşağıda verilmiştir:

- Olmez, Y., Sengur, A., Koca, G. O. (2020). Multilevel thresholding with metaheuristic methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36, 213-224. doi: 10.17341/gazimmfd.727811.
- Olmez, Y., Sengur, A., Koca, G. O., & Rao, R. V. (2023). An adaptive multilevel thresholding method with chaotically-enhanced Rao algorithm. *Multimedia Tools and Applications*, 82(8), 12351-12377.
- Olmez, Y., Koca, G. O., Tanyildizi, E., & Sengur, A. (2023). Multilevel image thresholding based on Renyi's entropy and golden sinus algorithm II. *Neural Computing and Applications*, 1-14.
- Olmez, Y., Koca, G. O., Sengur, A., & Acharya, U. R. (2023). PS-VTS: particle swarm with visit table strategy for automated emotion recognition with EEG signals. *Health Information Science and Systems*, 11(1), 22.
- Olmez, Y., Koca, G. O., Sengur, A., Acharya, U. R. & Mir, H. (2023). Improved PSO with Visit Table and Multiple Direction Search Strategies for Skin Cancer Image Segmentation. *IEEE Access*, vol. 12, pp. 840-867, 2024, doi: 10.1109/ACCESS.2023.3347587.
- Olmez, Y., Koca, G. O., Sengur, A., Acharya, U. R. (2023). Chaotic Opposition Golden Sinus Algorithm for Global Optimization Problems. (Under-review process).

1.4. Tezin Organizasyonu

Bu doktora tezi beş bölümden oluşmaktadır. **Birinci bölümde**, öncelikle tezin konusuyla alakalı detaylı bir literatür taraması ve analizi gerçekleştirilmiştir. Çalışmanın amaçları belirtilerek literatüre olan katkılar ortaya konmuştur. Sonunda tez organizasyonu ile bu bölüm tamamlanmıştır. **İkinci bölümde**, tez çalışması boyunca ele alınan ve geliştirilen yöntemlerin temelini oluşturan optimizasyon algoritmaları, bu algoritmalara dayalı görüntü eşikleme yöntemleri ve geliştirilen yöntemlerin değerlendirilmelerinde kullanılan kalite ölçüm indeksleri hakkında bilgilere yer verilmiştir.

Üçüncü bölümde, materyal ve metot sunulmuştur. Bu bölüm üç alt başlıkta incelenmiştir. İlk kısımda materyallere yer verilmiştir. Çalışmada kullanılan problemler, fonksiyonlar ve verisetleri hakkında detaylı bilgiler sunulmuştur. Geliştirilen yöntemler, çok seviyeli görüntü eşikleme ve duygu sınıflandırılması şeklinde iki alt başlıkta incelenmiştir. Aşağıda maddeler halinde gerçekleştirilen yöntemler hakkında kısaca bilgi verilmiştir:

- ✓ Birinci yöntemde, görüntü bölütleme performansını geliştirmek amacıyla güncel bir optimizasyon algoritması olan Altın Sinus Algoritmasının (Golden Sinus Algorithm II – GoldSa II) çok seviyeli eşiklemedeki etkililiği araştırılmıştır. Bu kapsamda, Renyi'nin entropisine ve GoldSa II algoritmasına dayalı yeni çok seviyeli bir görüntü eşikleme yöntemi geliştirilmiştir. Önerilen yöntem ile farklı histogramlara sahip 300 görüntü üzerinde bölütleme çalışmaları yapılmıştır. Yaklaşımın etkililiği analiz edilerek deneysel sonuçlar mevcut yöntemlerle karşılaştırmalı olarak sunulmuştur. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yazılmıştır [110].
- ✓ İkinci yöntemde, GoldSa yönteminin keşif (exploration) ve sömürü (exploitation) yeteneklerinin verimliliğini artırmak için kaotik haritalarla zenginleştirilmiş karşıtlık tabanlı bir Altın Sinüs Algoritması (Chaotically enhanced opposition based GoldSa-CoGoldSa) geliştirilmiştir. Geliştirilen yöntem, kıyaslama fonksiyonları ve klasik mühendislik tasarım problemleri üzerinde detaylı olarak analiz edilmiştir. Ayrıca, göğüs kanserinin patolojik görüntülerin segmentasyonu için Co-GoldSa yöntemine ve Renyi'nin entropisine dayanan etkili bir görüntü bölütleme şeması sunulmuştur. Yöntemin etkililiği, iyi bilinen ve yeni tanıtılan meta-sezgisel yaklaşımlarla karşılaştırmalı olarak analiz edilmiştir. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yazılmıştır.
- ✓ Üçüncü yöntemde, literatürde manuel olarak belirlenen eşik seviyesini otomatik olarak belirleyen bir yaklaşım geliştirilmiştir. Burada, literatürdeki metaforlara dayalı ve oldukça karmaşık olan yaklaşımların yerine basit bir optimizasyon tekniği kullanılmıştır. Eşikleme problemini basitleştiren kaotik olarak geliştirilmiş Rao (Chaotically Enhanced Rao-CER) algoritması çok seviyeli görüntü bölütleme için önerilmiştir. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yazılmıştır [109].

- ✓ Dördüncü yöntemde, literatürde mevcut olan optimizasyon algoritmalarının çok seviyeli görüntü eşiklemedeki performansları araştırılmıştır. Bu kapsamda, 2D yerel olmayan ortalamalar histogramına ve PSO yöntemine dayalı yeni bir bölütleme yaklaşımı (2DYOH-PSO) geliştirilmiştir. Önerilen yöntem, Berkley-Benchmark veri seti (Berkley-Benchmark Data Set- BSDS) üzerinde test edilmiştir ve literatürdeki yöntemlerle performans karşılaştırmaları yapılmıştır. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yayınlanmıştır [108].
- ✓ Beşinci yöntemde, cilt kanseri görüntülerinin sınıflandırılmasını geliştirmek amacıyla bölütleme performanslarının geliştirilmesi üzerinde durulmuştur. Bu amaçla, Ziyaret Tablosu Stratejisine dayalı Parçacık Sürü (Particle Swarm with Visit Table Strategy - PS-VTS) optimizasyon algoritması geliştirilmiştir. Önerilen yaklaşım, orijinal PSO algoritmasının güncelleme mekanizmasına bir ziyaret tablosu stratejisi ekleyerek gereksiz aramaları önlemektedir. Ayrıca, popülasyonun çeşitliliğini artırarak yerel optimuma takılmasını engellemek amacıyla yeni bir güncelleme eşitliği de yönteme eklenmiştir. Önerilen PS-VTS yönteminin performansı 50 test fonksiyonu üzerinde nicel, nitel ve ölçülebilirlik analizleri ile değerlendirilmiştir. Bununla birlikte, önerilen PS-VTS yöntemine dayalı görüntü bölütleme yaklaşımı geliştirilerek cilt kanseri görüntülerinin bölütlenmesi gerçekleştirilmiştir. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yazılmıştır [112].
- ✓ Altıncı yöntemde, EEG sinyallerinden duyguları belirlemek için EEG ritimlerini, derin CNN özelliklerini, SVM'yi ve optimizasyon yaklaşımını içeren verimli ve uyarlanabilir bir duygu tanıma çerçevesi önerilmiştir. Bu kapsamda, PS-VTS optimizasyon algoritmasına dayalı EEG sinyalleri ile duygu sınıflandırması yapılmıştır. EEG duygu tanıma için en etkili kanallar ve ritim kombinasyonları araştırılmıştır. Literatürde manuel olarak seçilen EEG kanallarının ve ritimlerinin seçiminin otomatik olarak gerçekleştirilmesi için iki model geliştirilmiştir. Önerilen yaklaşım DEAP veri seti üzerinde test edilmiştir. Sonuçlar, önerilen yaklaşımın daha az EEG kanalıyla en yüksek duygu sınıflandırma doğruluğunu elde ettiğini göstermiştir. Bu bölümde gerçekleştirilen çalışmalar değerlendirilerek bir makale yazılmıştır [111].

Dördüncü bölümde, bulgular ve tartışmalara yer verilmiştir. Burada, geliştirilen yöntemlerin uygulamalarına ve bu uygulamalardan elde edilen sonuçlara yer verilmiştir.

Beşinci bölümde, tüm çalışmaların bulguları genel hatları ile ele alınarak geliştirilen yöntemlerin analizleri yapılmıştır ve özgünlüğü ve başarımları vurgulanmıştır.

Son olarak, geliştirilen her yöntem ve uygulama alanındaki eksikliklerden, bu eksikliklere yönelik geliştirilebilecek yöntemlerden ve gelecek çalışmalardan bahsedilmiştir.

2. ÖN BİLGİLER


Bu bölümde, tez çalışmasında kullanılan optimizasyon algoritmaları, bu algoritmalara dayalı çok seviyeli eşikleme yöntemleri ve EEG sinyalleri ile ilgili temel bilgilere yer verilmiştir. Ayrıca, çalışmada kullanılan problemler ve veri setleri de bu bölümde sunulmuştur.

2.1. Optimizasyon Algoritmaları

Optimizasyon, aynı kriterlere sahip alternatifler arasından en iyinin seçilmesidir. Bu seçim, deterministik veya stokastik yöntemlerle gerçekleştirilebilir. Deterministik yöntemler, belirli ve öngörülebilir adımlar kullanarak bir optimizasyon problemi veya matematiksel modelin çözümünü bulmaya odaklanır. Bu yöntemler, sistematik ve belirlenen kurallara dayalı bir yaklaşımı benimser. Ancak bu yöntemler büyük ölçekli veya karmaşık problemler için uzun ve yorucu bir süreçle sahiptir. Bu tür problemlere alternatif çözüm stokastik yöntemler kullanmaktır. Stokastik yöntemler, özellikle belirsizlik altında bulunan problemlerin çözümünde ve karmaşık, çok boyutlu problemlerin ele alınmasında oldukça etkilidir. Belirli bir problem için en uygun çözümü bulmaya çalışan meta-sezgisel algoritmalar, stokastik yöntemlerden yararlanır.

Optimizasyon algoritmaları, ayırıcı özelliklere dayalı olarak çeşitli şekillerde kategorize edilebilmektedir. Blum ve Roli [113], meta sezgiselleri doğadan ilham alan ve doğadan ilham almayan olarak iki kategoriye ayırmışlardır. Popülasyon-tabanlı veya tek nokta araması tabanlı, amaç fonksiyonunun dinamik veya statik olup olmadığı, bellek kullanımı veya belleksiz yaklaşımlar olması, bir veya daha fazla komşuluk yapısının olması şeklinde farklı amaçlar gözetilerek, Mirjalili ve Lewis [114] metasezgisel algoritmaları şu şekilde sınıflandırmıştır: evrimsel, fizik tabanlı, sürü tabanlı ve insan tabanlı algoritmalar. Nüfusa dayalı bir sınıflandırma Beheshti ve ark. tarafından 2013 yılında sunulmuştur [115]. Benzer şekilde, çeşitli ayırıcı özelliklere dayalı olarak metasezgisellerin sınıflandırmaları araştırmacılar tarafından farklı şekillerde yapılmıştır [116], [117], [118], [119], [120], [121]. Yapılan sınıflandırmalar incelendiğinde, en genel haliyle meta-sezgisel yöntemler dört ana kategoriye ayrılabilir (Şekil 2.1.). Bunlar; evrimsel algoritmalar, sürü zekasına dayalı algoritmalar, insana dayalı algoritmalar ve fiziksel fenomenlere dayalı algoritmalar.

Darwin'in teorisinin biyolojik evriminden ilham alan evrimsel algoritmalar seçim ve üreme gibi genetik operatörleri içerir. Genetik Algoritma [122], Memetik algoritma [123] bu grubun iyi bilinen örnekleri arasındadır. Sürü zekasına dayalı algoritmalar, hayvanların veya bireysel olarak zeki olmayan diğer türlerin sürü zekasından ilham alır, ancak grup olarak çalıştıklarında zeki hale gelirler. Bu gruptaki bilinen örnekler arasında Gri Kurt optimizasyonu [124], Yapay Arı Kolonisi algoritması [125] ve Karınca Kolonisi [87] sayılabilir.



Şekil 2.1 Metasezgisel Algoritmaların Sınıflandırılması

Fiziksel Fenomenlere dayalı algoritmaları, fiziksel olaylara ve yerçekimi kuvveti gibi bilim yasalarına dayalı olarak tasarlanmıştır. Merkezi kuvvet optimizasyonu [126] ve Yerçekimi Arama Algoritması [89] bu gruba örnektir. İnsana dayalı algoritmalar insan davranışlarından ilham alarak geliştirilmiştir. Bu algoritmalarından en popüler olanları, öğretme öğrenme temelli optimizasyon (Teaching Learning Based Optimization-TLBO) [127], [128], uyum arama (Harmony Search-HS) optimizasyonu [129], tabu arama (Taboo Search-TS) [130], [131], grup arama optimizasyonu (Group Search Optimizer-GSO) [132] şeklinde sıralanabilir. Bu tez çalışmasında kullanılmış optimizasyon algoritmaları GoldSa II, PSO, Rao algoritmalarına ait temel bilgiler aşağıda ayrı ayrı başlıklar halinde verilmiştir.

2.1.1. Altın Sinus Algoritması

GoldSa II, orijinal GoldSa optimizasyon yöntemine dayalı olarak önerilen metasezgisel bir yöntemdir [133]. Algoritması, azalan model bir sinüs fonksiyonu ve altın oran kullanılarak

geliştirilmiştir. Bu algoritmada, her aday çözüm arama ajanı olarak oluşturulur. Gold-Sa operatörü aday çözümleri hedef çözüme ulaşmaya zorlar. Kullanılan sinüzoidal dalga formunun denklemi aşağıda verilmiştir:

$$V(t) = A. \sin(\omega. t) \quad (2.1)$$

Burada, $w=2.\pi.Fc$ ve $Fc=100$ Hz şeklinde kullanılmaktadır. Altın Kesit Arama yönteminde, (2.2) ve (2.3) numaralı eşitlikler kullanılarak optimum değer elde edilmektedir.

$$x_1 = a. (1 - \tau) + b. \tau \quad (2.2)$$

$$x_2 = a. \tau + b. (1 - \tau) \quad (2.3)$$

Burada, τ altın orandır. (a,b) aranacak aralığı ifade eder ve bu değerler;

$$a = -dr_t. \pi. rand \quad (2.4)$$

$$b = dr_t. \pi. rand \quad (2.5)$$

eşitlikleri ile belirlenmektedir. Burada, *rand* ifadesi (0,1) aralığında rastgele üretilen bir sayısı ifade etmektedir. dr_t ise sinüs fonksiyonunun genliğini temsil etmektedir. Bu çalışmada, dr_t değeri $dr_t = 2. (1 - t)/t_{max}$ eşitliği kullanılarak hesaplanmaktadır. Popülasyon tabanlı optimizasyon yöntemlerinde, optimizasyon süreci tipik olarak iki kısma ayrılır: keşif ve sömürme. Arama uzayının gelecek vaat eden konumlarını keşfetmek için, bir optimizasyon yöntemi başlangıçta çözüm uzayındaki rasgele çözümleri yüksek bir rastgelelik oranıyla bütünleştirir. Bununla birlikte, sömürme aşamasında, rastgele çözümler kademeli olarak değişir ve rastgele varyasyonlar, keşif aşamasına göre oldukça küçüktür. Pozisyonlar, Eş. (2.6) ile her iki aşama için de güncellenir:

$$X_i^{t+1} = \begin{cases} X_i^t - dr_t. \sin(w * t * r_1). (r_2 * x_1 D_p - x_2. X_i^t), & r_3 < 0.5 \\ X_i^t + dr_t. \sin(w * t * r_1). (r_2 * x_1 D_p - x_2. X_i^t), & r_3 > 0.5 \end{cases} \quad (2.6)$$

Burada, X_i^{t+1} ve X_i^t ifadeleri ajanların şuanki ve gelecekteki değerleri, dr_t sinüs fonksiyonunun genliğini temsil etmektedir. r_1 ve r_2 rastgele değerlerdir. x_1 ve x_2 ise altın kesit yönteminden elde edilen katsayıları ifade etmektedir.

2.1.2. Rao1 Algoritması

Rao algoritmaları, yakın zamanda geliştirilen basit ve metafor içermeyen üç optimizasyon algoritmasından oluşur [134]. Çalışmada Rao algoritmalarının kısıtlı/kısıtsız mühendislik optimizasyon problemlerinin çözümünde oldukça başarılı sonuçlar elde ettiği görülmüştür. Bu algoritmalar yalnızca, tüm optimizasyon algoritmalarında ortak olan ve herhangi bir özel kontrol parametresi gerektirmeyen yineleme sayısı ve popülasyon boyutu gibi basit kontrol parametrelerini kullanması bakımında son zamanlarda tanıtılan oldukça karmaşık yöntemlere kıyasla karmaşıklıktan uzak basit yöntemlerdir. Problem için rastgele oluşturulmuş aday çözümler ile yinelemeler sırasında belirlenen en iyi/en kötü çözümler arasındaki etkileşimlere dayanır. Üç Rao

algoritmasından en basit olan Rao-1 algoritması bu çalışmada da kullanılmıştır. Rao-1 algoritmasına göre aday çözümler Eş. (2.7) kullanılarak güncellenir:

$$x'_{j,k} = x_{j,k} + r_1(best_{j,i} - worst_{j,i}) \quad (2.7)$$

Burada, $x_{i,j}$ ve $x'_{i,j}$ ifadeleri j^{nci} iterasyonda i^{nci} çözümün şu anki ve gelecekteki değerleridir. $best_{i,j}$ ve $worst_{i,j}$ ifadeleri ise tüm çözümün en iyi ve en kötü değerlerini temsil etmektedir. r_1 ise (0,1) aralığında rastgele bir değeri ifade etmektedir.

2.1.3. Parçacık Sürü Algoritması

Parçacık Sürü Optimizasyonu (PSO), Kenedy ve ark. tarafından kuş ve balık sürülerinin davranışlarından esinlenerek geliştirilen popülasyon tabanlı bir yöntemdir [85]. Algoritma rastgele çözümlerden oluşan bir popülasyonla başlar ve nesilleri güncelleyerek en uygun çözümü arar. PSO'da parçacık adı verilen olası çözümler, o anki optimum parçacığı takip ederek problem uzayında dolaşır. Her parçacık önceki deneyimlerinden yararlanarak sürüdeki en iyi konuma doğru konumunu ayarlar. Parçacıkların hız ve pozisyon güncelleme denklemleri sırasıyla Eş. (2.8) ve (2.9)'da verilmiştir:

$$v_{ij}(k+1) = v_{ij}(k) + C_1 \cdot rand_1(P_{best,ij}(k) - x_{ij}(k)) + C_2 \cdot rand_2(g_{best,ij}(k) - x_{ij}(k)) \quad (2.8)$$


$$x_{ij}(k+1) = x_{ij}(k) + v_{ij}(k+1) \quad (2.9)$$

Burada, $v_{ij}(k)$ ve $v_{ij}(k+1)$ ifadeleri kuşların şuanki ve gelecekteki hızlarını gösterir. $x_{ij}(k+1)$ ve $x_{ij}(k)$ ifadeleri ise kuşların şuanki ve gelecekteki pozisyonlarını göstermektedir. $P_{best,ij}$ ifadesi i^{nci} kuşun o ana kadar ki en iyi değeri (local optimum) ve $g_{best,ij}$ ifadesi ise tüm çözümlerin en iyisini (global optimum) ifade etmektedir. C_1 ve C_2 ifadeleri hızlandırma faktörleri, $rand_1$ ve $rand_2$ ise (0,1) aralığında rastgele alınan değerlerdir.

2.2. Optimizasyon Algoritmalarına Dayalı Görüntü Eşikleme Yöntemleri

Bu bölümde, tez çalışmasında kullanılan görüntü eşikleme yöntemleri kısaca açıklanmıştır. Optimizasyon algoritmalarına dayalı olarak yapılan çok seviyeli görüntü eşikleme için genel bir akış diagramı Şekil 2.2'de sunulmuştur. Şekil 2.2'yi adım adım açıklayacak olursak; ilk adımda giriş görüntüsü alınarak seçilen yönteme göre görüntü histogramı çıkarılır. Çıkarılan histogram eşikleme yöntemine ve dolayısıyla optimizasyon algoritmasına giriş olarak verilir. Yöntem için uygun metasezgisel algoritma seçildikten sonra uygunluk fonksiyonuna karar vermek gerekmektedir. Bu aşamada uygunluk fonksiyonu olarak Otsu'nun maksimum varyansı, Renyi'nin entropisi, Kapur'un entropisi, Tsalli's entropisi, vb gibi pek çok seçenek bulunmaktadır.

Gerçekleştirilecek uygulama için uygun görülen eşikleme yöntemi belirlendikten sonra bu yöntem metasezgisel algoritmanın uygunluk fonksiyonu olarak atanır.



Şekil 2.2. Metasezgisel yöntemlere dayalı görüntü bölütleme akış diagramı

Metasezgisel algoritmada verilen giriş görüntüsü için belirtilen seviyede optimum eşik değerleri aranır. Elde edilen optimum eşik değerleri ile görüntü bölütlenerek değerlendirmeleri gerçekleştirilir. Burada referans görüntüsü olarak birden çok insan tarafından bölütlenmiş görüntüler alınabilir. Değerlendirme kriterleri olarak; Sınır yer değiştirme hatası (Boundary Displacement Error-BDE) [135], Bilgi varyasyonu (Variance of Information-VOI) [135], Global tutarlılık hatası (Global Consistency Error-GCE) [135], Olasılık rand endeksi (Probability Rand Index-PRI), Tepe sinyal gürültü oranı (Peak Signal to Noise Ratio-PSNR) [135], Yapısal benzerlik indeksi (Structural Similarity-SSIM) [135], Özellik benzerlik indeksi (Feature Similarity-FSIM) [136], Hatanın ortalama karekökü (Root Mean Squared Error-RMSE) [137], Çapraz korelasyon (Cross Correlation-CC) [137], Ortalama fark (Average difference-AD)[137], Maksimum fark (Maximum Difference-MD) [137], Normalleştirilmiş mutlak hata (Normalized Absolute Error-NAE) [46], vb görüntü kalite ölçüm indeksleri kullanılabilir.

Bu çalışmada, uygunluk fonksiyonu olarak en yaygın kullanılan eşikleme yöntemlerinden Renyi'nin entropisi ve Otsu'nun Sınıflar Arası Varyansı kullanılmıştır. Bu yöntemler ile ilgili temel bilgilere aşağıda yer verilmiştir.

2.2.1. Renyi'nin Entropisi

Renyi'nin entropisi, yaygın kullanılan eşikleme yöntemlerinden biridir. $M \times N$ boyutlu bir görüntü olsun ve bu görüntü L gri seviyelerinde gösterilsin. Gri seviyelerin olasılık dağılımları $p_0, p_1, \dots, p_L$ olarak ifade edilsin. Bu görüntünün olasılık dağılımları,

$$p_i = \frac{n_i}{M \times N} \quad (2.10)$$

eşitliği kullanılarak türetilmektedir. Burada n_i , i 'inci gri seviyedeki piksellerin tekrarlanma sıklığını temsil etmektedir. T eşik değeri, pikselleri nesne (Sınıf A) ve arka plan (Sınıf B) olmak üzere iki sınıfa ayırır. Renyi'nin arka plan ve ön plan entropileri şu şekilde hesaplanır [138]:

$$H_A = \frac{1}{1-q} \ln \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} \left(\frac{p_i}{p_A}\right)^q \quad (2.11)$$

$$H_B = \frac{1}{1-q} \log \sum_{i=s}^{L-1} \sum_{j=t}^{L-1} \left(\frac{p_i}{p_B}\right)^q \quad (2.12)$$

Burada, q pozitif gerçel sayıdır ve $q \neq 1$ 'dir. p_i , olasılık dağılım matrisini ifade etmektedir. H Renyi'nin toplam entropisini göstermektedir ve $H = H_A + H_B$ olarak ön plan ve arka plan entropilerinin toplamı ile elde edilir. Renyi'nin entropisi maksimuma ulaştığında, karşılık gelen gri seviye değeri optimum eşik değeri olarak belirlenir.

2.2.2. Otsu'nun Maksimum Varyansı

Sınıflar arası varyans yöntemi olarak da bilinen Otsu'nun yöntemi, denetimsiz, parametrik olmayan ve otomatik bir yöntemdir [7]. Bu algoritmada, nesnenin ortalama gri seviyesi (ön plan) ile arka planın gri seviyesi arasındaki maksimum fark bulunarak optimum eşik değeri elde edilir. Elde edilen optimum eşik değeri ile görüntü bölümlere ayrılır. İki düzey için, görüntü uygunluk fonksiyonu $f: = \sigma_0^2 + \sigma_1^2$ tarafından tek eşikli değeri (T) ile C_0 ve C_1 şeklinde iki sınıfa ayrılır. Ön plan ve arka plana ait varyanslar;

$$\sigma_0^2 = w_0(\mu_0 - \mu_T)^2 \quad (2.13)$$

$$\sigma_1^2 = w_1(\mu_1 - \mu_T)^2 \quad (2.14)$$

ile hesaplanır. Burada,

$$\mu_0 = \sum_{i=1}^t \frac{ip_i}{w_0} \quad (2.15)$$

$$\mu_1 = \sum_{i=t+1}^L \frac{ip_i}{w_1} \quad (2.16)$$

olarak hesaplanır. Eşitlikte w_0 and w_1 ifadeleri ön ve arka plan için sınıf olasılıklarıdır ve (2.17) ve (2.18) eşitlikleri aracılığıyla hesaplanır:

$$w_0(t) = P_r(C_0) = \sum_{i=1}^t p_i \quad (2.17)$$

$$w_1(t) = P_r(C_1) = \sum_{i=t+1}^L p_i = 1 - w_0(t) \quad (2.18)$$

2.3. Değerlendirme Ölçütleri

Bu bölümde, geliştirilen yöntemlerin başarımlarını değerlendirirken kullanılan performans değerlendirme ölçütleri verilmiştir. Bunlar; Yapılandırılmış Benzerlik İndeksi ([46], [139]), Özellik Benzerlik İndeksi [46], [136], Tepe Sinyal-Gürültü Oranı [46], [137], Ortalama Karesel Hata [46], [137], Olasılık Rand Endeksi [46], [140], Bilgi Varyasyonu [46], [140], Sınır Yer Değiştirme Hatası [46], [140], Global Tutarlılık Hatası [46], [140], Ortalama Fark [46], [137], Maksimum Fark [46], [137], Normalize Edilmiş Mutlak Fark [46], [46] ve Standart Sapmadır.

2.3.1. Yapılandırılmış Benzerlik İndeksi

Yapılandırılmış Benzerlik İndeksi (Structured Similarity Index-SSIM), orijinal resim ile bölütlenen resim arasındaki benzerliği ölçer. SSIM değerinin yüksek olması daha iyi bir bölütleme performansını ifade eder. Bu indeks, -1 ve 1 aralığında değerler alır. Yapısal bilgi SSIM tarafından görüntü kompozisyonu açısından parlaklık ve kontrasttan bağımsız olarak tanımlanır ve bu nesnelerin yapısının niteliklerini inceler ve distorsiyonu kontrast, parlaklık ve yapı faktörlerinin birleşimi olarak modeller. İki görüntü birebir aynı olduğunda SSIM değeri '1' değerini alır. SSIM değeri (2.19)'da verilen eşitlik ile hesaplanmaktadır.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (2.19)$$

Burada, $c_1 = (k_1 L)^2$ ve $c_2 = (k_2 L)^2$ 'dir. Ayrıca, $k_1 = 0.01$ ve $k_2 = 0.03$ olarak alınabilir. x ve y ifadeleri, sırasıyla orijinal ve bölütlenmiş görüntülerdir. μ_x ve μ_y ise sırasıyla orijinal ve bölütlenmiş görüntünün gri seviyelerinin ortalamasıdır. σ_{xy} orijinal ve bölütlenmiş görüntülerin gri seviyeleri arasındaki kovaryansı temsil etmektedir. σ_x^2 orijinal görüntünün gri seviyelerinin varyansı ve σ_y^2 ise bölütlenmiş görüntünün gri seviyelerinin varyansını ifade etmektedir. Ortalama parlaklık tahmini olarak, Std kontrast tahmini olarak kullanılırken kovaryans SSIM ölçüsü olarak kullanılır.

2.3.2. Özellik Benzerlik İndeksi

Özellik Benzerlik İndeksi (Feature Similarity Index-FSIM), orijinal resim ile bölütlenen resim arasındaki benzerliği değerlendiren başka ölçüm birimidir. FSIM değeri $[-1, 1]$ aralığındadır. Yüksek FSIM değeri daha iyi eşikleme performansını göstermektedir. Eşik seviyesi arttıkça bu değerler de artış göstermektedir. Referans görüntü ve bölütlenmiş görüntü için FSIM değeri (2.20) kullanılarak hesaplanmaktadır.

$$FSIM(x, y) = \frac{\sum_{x \in \Omega} S_L(x) PC_m(x)}{\sum_{x \in \Omega} PC_m(x)} \quad (2.20)$$

Burada, Ω ifadesi tüm görüntü uzayını temsil etmektedir. $PC(m) = \max(PC_1 + PC_2)$ 'dir ve PC_1 ve PC_2 sırasıyla orijinal ve bölütlenmiş görüntünün faz tutarlılığını ifade etmektedir.

2.3.3. Tepe Sinyal-Gürültü Oranı

Tepe Sinyal-Gürültü Oranı (Peak Signal to Noise Ratio-PSNR), farklı dinamik aralıklara sahip görüntüleri karşılaştırmak için kullanılmaktadır. Yüksek PSNR değeri daha iyi bir eşikleme performansını ifade eder. Referans görüntü ve bölütlenmiş görüntü için PSNR değerinin formülasyonu,

$$PSNR = 10 \log_{10} \frac{255^2}{MSE} \quad (2.21)$$

şeklinde. Burada, MSE (Mean Square Error) orijinal görüntü ile bölütlenen görüntü arasındaki hatanın karesinin ortalamasını ifade etmektedir.

2.3.4. Ortalama Karesel Hata

Ortalama Karesel Hata (Mean Square Error-MSE), hatanın karesinin ortalamasını ölçmektedir. Düşük MSE değerleri iyi bir götüntü bölütlemesi yapıldığını gösterir. MSE denklemi, Eşitlik (2.22)'de verilmiştir:

$$MSE = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \|x(i,j) - y(i,j)\|^2 \quad (2.22)$$

Burada, $M \times N$ görüntünün boyutlarını temsil etmektedir. x ve y sırasıyla orijinal ve bölütlenmiş görüntüyü göstermektedir. $x(i,j)$ orijinal görüntünün (i,j) 'inci gri seviyesini temsil etmektedir. $y(i,j)$ ise bölütlenmiş görüntünün (i,j) 'inci gri seviyesini temsil etmektedir.

2.3.5. Olasılık Rand Endeksi

Olasılık Rand Endeksi (Probability Rand Index-PRI), iki görüntü arasındaki benzerlik ölçümünde kullanılır. Genellikle $[0,1]$ aralığında değer almaktadır. Yüksek PRI değeri iyi bir eşikleme performansını göstermektedir. PRI'nın formülasyonu Eş. (2.23)'te verilmiştir.

$$PRI = \frac{a+b}{a+b+c+d} \quad (2.23)$$

Burada, $a + b$ ifadesi iki görüntü arasındaki benzer piksellerin sayısı ve $c + d$ ifadesi iki görüntü arasındaki farklı piksellerin sayısını temsil etmektedir.

2.3.6. Bilgi Varyasyonu

Bilgi Varyasyonu (Variation of Information-VOI), ortalama koşullu entropi cinsinden iki bölümlenme arasındaki mesafeyi tanımlayarak bölümlenmiş bir görüntüdeki rastgelelik miktarını hesaplar. VOI, $[0, \infty)$ aralığında değer alır. Değer ne kadar küçükse sonuç o kadar iyi olur. VOI indeksinin formülasyonu,

$$VOI(x; y) = H(x) + H(y) - 2I(x, y) \quad (2.24)$$

ile hesaplanır. Burada, $H(x)$ ifadesi x görüntüsünün entropisini temsil etmektedir. $I(x, y)$ ifadesi ise x ve y görüntüsü arasındaki ortak bilgidir. VOI, $[0, \infty)$ aralığında değer alır. Daha iyi bölütleme için küçük VOI değeri tercih edilir.

2.3.7. Sınır Yer Değiştirme Hatası

Sınır Yer Değiştirme Hatası (Boundary Displacement Error-BDE), bölütlenmiş görüntüler arasında sınır piksellerin yer değiştirmesinin ortalama hatasını hesaplar. Görüntü sınırındaki piksel ile en yakın piksel arasındaki mesafe olarak tanımlanır. Daha iyi segmentasyon için daha düşük bir BDE değeri tercih edilir. BDE değeri, Eş. (2.25) kullanılarak hesaplanır:

$$BDE = \frac{1}{N} \sum_{i=1}^N d(b_g - b_t) \quad (2.25)$$

Burada, N ifadesi toplam nokta sayısını temsil etmektedir. $d(.)$ ifadesi, iki nokta arasındaki uzaklığı hesaplayan bir fonksiyondur. Bu fonksiyondaki b_g ve b_t ise gerçek nokta ve tahmin edilen noktayı ifade etmektedir.

2.3.8. Global Tutarlılık Hatası

Global Tutarlılık Hatası (Global Consistency Error-GCE), bir bölütlemenin diğerinin bir gelişimi olarak ne ölçüde gözlenebileceğini hesaplar. Değer ne kadar küçükse, bölümlendirme sonucu o kadar iyi olur. GCE'nin formülasyonu Eş (2.26) da verilmiştir.

$$GCE = \frac{1}{n} \{ \sum_i E(S_1, S_2, p_i), \sum_i E(S_2, S_1, p_i) \} \quad (2.26)$$

Burada, S_1 ve S_2 görüntüleri giriş olarak alınarak bölütleme hatası ölçülür. GCE endeksi $(0,1)$ aralığında bir çıktı üretir.

2.3.9. Ortalama Fark

Ortalama fark (Average difference-AD), referans görüntü ve bölütlenmiş görüntü arasındaki farkın ortalamasıdır. Daha iyi bir bölütleme için düşük AD değeri tercih edilir. AD değeri,

$$AD = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (x(i, j) - y(i, j)) \quad (2.27)$$

ile hesaplanır. Burada, $M \times N$ görüntü boyutlarını ifade etmektedir. x ve y giriş olarak alınan referans görüntü ve bölütlenmiş görüntüyü temsil etmektedir. $x(i, j)$ ifadesi ise x görüntüsündeki i^{nci} satır ve j^{nci} sütundaki piksel değerini göstermektedir.

2.3.10. Maksimum Fark

Maksimum fark (Maximum difference-MD), iki görüntü arasındaki hatanın maksimumunu alır. MD değerinin küçük olması, daha iyi bölütlemeyi ifade eder. MD eşitliği;

$$MD = \max |x(i, j) - y(i, j)| \quad (2.28)$$

olarak hesaplanır. Burada, x ve y referans görüntü ve bölütlenmiş görüntüyü temsil etmektedir. $x(i, j)$ ifadesi ise x görüntüsündeki i^{nci} satır ve j^{nci} sütundaki piksel değerini göstermektedir.

2.3.11. Normalize Edilmiş Mutlak Fark

Normalize edilmiş mutlak fark (Normalized Absolute Error-NAE), iki görüntü arasındaki normalleştirilmiş mutlak farkı hesaplar. İyi bir bölütleme için düşük NAE değeri tercih edilir. NAE değeri Eş. (2.29) ile hesaplanır:

$$NAE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |x(i, j) - y(i, j)| \quad (2.29)$$

Burada, $M \times N$ görüntü boyutlarını ifade etmektedir. $x(i, j)$ ve $y(i, j)$ ifadeleri giriş olarak alınan referans görüntü ve bölütlenmiş görüntünün i^{nci} satır ve j^{nci} sütundaki piksel değerlerini göstermektedir.

2.3.12. Standart Sapma

Standart sapma endeksi ortalamadaki değişimi ölçer, düşük standart sapma değerlerinde algoritma daha kararlı çalışır. Standart sapma değeri,

$$s_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (2.30)$$

Eşitliği kullanılarak hesaplanır. Burada, n toplam örnek sayısı ve x_i örneklerin her birini temsil etmektedir. $\bar{x}$ ifadesi ise x_i 'nin ortalamasını göstermektedir.

3. MATERYAL VE METOT

Bu bölümde, çalışmada kullanılan problemler ve verisetleri, görüntü eşikleme ve duygu sınıflandırmasında geliştirilen yöntemler hakkında bilgilere yer verilmiştir. Birinci bölümde, uygulanan test fonksiyonları, mühendislik tasarım problemleri ve uygulanan verisetleri hakkında detaylı bilgilere yer verilmiştir. İkinci bölümde, görüntü eşikleme performansını artırmak amacıyla geliştirilen algoritmalar ve yöntemler alt başlıklar halinde verilmiştir. Son bölümde ise EEG sinyallerinden duygu sınıflandırma başarımının artırılmasına yönelik olarak geliştirilen yöntem sunulmuştur.

3.1. Uygulanan Problemler ve Verisetleri

Bu tez çalışmasında, yöntemlerin performansları çok yönlü incelenmiş olup farklı alanlarda pek çok fonksiyon, veriseti ve görüntüler üzerinde analizler yapılmıştır. Bu bölümde, gerçekleştirilen çalışmalarda kullanılan tüm verisetleri, görüntüler ve fonksiyonlar hakkında kısaca bilgilendirmelerde bulunulmuştur. Üzerinde çalışılan problemler ve verisetleri;

- ✓ Test fonksiyonları,
- ✓ Klasik mühendislik problemleri,
- ✓ BSDS300-Berkeley-Benchmark Veriseti [141],
- ✓ ISIC2017-Deri Kanseri Görüntüleri Veri Seti [142],
- ✓ BIDC-Göğüs Kanseri Görüntüleri Veri Seti [143],
- ✓ DEAP-EEG Sinyalleri Veri Seti [144]

şeklinde özetlenebilir.

3.1.1. Test Fonksiyonları

Test fonksiyonları, optimizasyon tekniklerinin performansını değerlendirmek ve karşılaştırmak için optimizasyon algoritmalarında yaygın olarak kullanılan matematiksel fonksiyonlardır. Bu işlevler, optimizasyon algoritmalarının etkinliğini ve verimliliğini değerlendirmek için standartlaştırılmış test problemleri olarak kullanılır. Karşılaştırma işlevleri genellikle gerçek dünyadaki optimizasyon zorluklarını taklit etmek için dışbükeylik, çok modluluk veya doğrusal olmama gibi belirli özelliklere sahip olacak şekilde tasarlanmıştır. Optimizasyonda kullanılan yaygın benchmark fonksiyonları tek modlu/çok modlu, kısıtlı/kısıtsız ve gürültülü fonksiyonlar olarak sınıflandırılmaktadırlar. Bunlardan; tek modlu fonksiyonlar, tek bir genel (global) minimuma (veya maksimuma) sahiptir ve yerel (lokal) minimumları (veya maksimumları) yoktur. Çok modlu fonksiyonlar ise birden çok lokal minimuma (veya maksimuma) sahip olduğu gibi bir de global minimuma (veya maksimuma) sahiptir. Kısıtlı fonksiyonlar, optimizasyon

problemine kısıtlamalar ekler. Kısıtlamalar eşitlik veya eşitsizlik kısıtlamaları şeklinde olabilir. Gürültülü fonksiyonlar ise hedef fonksiyon değerlemesine gürültü ekler ve gerçek dünya senaryolarını taklit eder, nesnel fonksiyonlar ölçüm hatalarına veya stokastik değişkenliğe maruz kalabilecekleri durumlarla karşılaşabilir.


Benchmark fonksiyonları, optimizasyon algoritmalarını karşılaştırmak ve değerlendirmek için önemli araçlardır. Farklı tekniklerin güçlü ve zayıf yönlerini anlamaya ve yeni optimizasyon yöntemlerinin gelişimini yönlendirmeye yardımcı olurlar. Farklı problem alanlarında optimizasyon algoritmalarının adil bir şekilde karşılaştırılması ve değerlendirilmesi için standart bir platform sağlarlar. Bu çalışmada, optimizasyon algoritmasını farklı açılardan değerlendirmek için geliştirilen yöntemlerin performansı, çeşitli özelliklere sahip fonksiyonlardan oluşan 50 kıyaslama fonksiyonu üzerinde test edilmiştir. Bu tez çalışmasında kullanılan kıyaslama fonksiyonları Ek 1-3'te verilmiştir. Bahsedilen test fonksiyonlarından 17'si tek modlu (unimodal) ve 33'ü çok modludur (multimodal).

3.1.2. Klasik Mühendislik Tasarım Problemleri

Bu çalışmada, çekme/basma yayı tasarımı ve kaynaklı kiriş tasarımı, basınçlı boru tasarımı ve üç çubuklu kafes tasarım problemi olmak üzere dört klasik mühendislik tasarım problemi kullanılmıştır. Problemlerin detayları aşağıda detaylı olarak açıklanmıştır.

a) Çekme/Basma Yay Tasarım Problemi

Bu mühendislik probleminin amacı üç değişken ile dört kısıtlamayı karşılamak için yayın ağırlığını en aza indirmektir. Bu tasarım problemi bobin sayısı (N), bobin çapı (D) ve tel çapı (d) olmak üzere 3 değişkene sahiptir. Çekme/Basma yay tasarım modeli Şekil 3.1'de sunulmuştur.



Şekil 3.1. Çekme/Basma yay tasarım modeli

Bu problemde dikkate alınan 3 geometrik değişken ve 4 kısıt vardır. Belirtilen $[d, D, N]$ değişkenleri, matematiksel ifadelerde $\vec{x} = [x_1, x_2, x_3]$ olarak alınmıştır. Probleme ilişkin maliyet fonksiyonu aşağıdaki eşiklikte tanımlanmıştır:

$$f_1(\vec{x}) = (x_3 + 2) \cdot x_2 \cdot x_1^2 \quad (3.1)$$

Problem için $[d, D, N]$ değişkenlerine yönelik belirtilen kısıtlar ise aşağıdaki gibi verilmiştir:

$$g_1(\vec{x}) = 1 - \frac{x_3 x_2^3}{71785 x_1^4} \leq 0 \quad (3.2)$$

$$g_2(\vec{x}) = \frac{4x_2^2 - x_1 x_2}{12566(x_2 x_1^3 - x_1^4)} + \frac{1}{5108 x_1^2} - 1 \leq 0 \quad (3.3)$$

$$g_3(\vec{x}) = 1 - \frac{140.45 x_1}{x_2^2 x_1} \leq 0 \quad (3.4)$$

$$g_4(\vec{x}) = \frac{x_1 + x_2}{1.5} - 1 \leq 0 \quad (3.5)$$

Benzer şekilde, $[d, D, N]$ değişkenleri için aralıklar aşağıdaki eşitlerde verildiği haliyle kullanılmıştır:


$$0.05 \leq x_1 \leq 2 \quad (3.6)$$

$$0.25 \leq x_2 \leq 1.3 \quad (3.7)$$

$$2 \leq x_3 \leq 15 \quad (3.8)$$

b) Kaynaklı Kiriş Tasarım Problemi

Kaynaklı kiriş tasarım probleminde, kaynaklı kirişin maliyetini en aza indirmek amaçlanmaktadır. Bu problem, çubuk kalınlığı (b), kaynağın kalınlığı (h), çubuk yüksekliği (t) ve bağlanan parçanın uzunluğu olarak dört değişkene sahiptir. Kaynaklı bir kaynaklı kiriş tasarım modeli Şekil 3.2’de sunulmuştur.



Şekil 3.2. Kaynaklı kiriş tasarım modeli

Belirtilen değişkenler iki doğrusal ve beş doğrusal olmayan eşitsizlik koşullarıyla sınırlandırılmıştır. Problemin ait değişkenler $[h, l, t, b]$ aşağıdaki matematiksel ifadelerde $\vec{x} = [x_1, x_2, x_3, x_4]$ olarak alınmıştır. Kaynaklı kirişin maliyetini en aza indirmek amacıyla kullanılan fonksiyon aşağıdaki eşitlikte ifade edilmiştir:

$$f_2(\vec{x}) = 1.10471 x_1^2 x_2 + 0.04811 x_3 x_4 (14 + x_2) \quad (3.9)$$

Bu problemin deęişkenleri için kısıtlar ařaęıdaki eřitliklerde g r lmektedir.

$$g_1(\vec{x}) = T(x) + T_{max} \leq 0 \quad (3.10)$$

$$g_2(\vec{x}) = \sigma(\vec{x}) + \sigma_{max} \leq 0 \quad (3.11)$$

$$g_3(\vec{x}) = \delta(\vec{x}) + \delta_{max} \leq 0 \quad (3.12)$$

$$g_4(\vec{x}) = x_1 - x_4 \leq 0 \quad (3.13)$$

$$g_5(\vec{x}) = P - P_c(\vec{x}) \leq 0 \quad (3.14)$$

$$g_6(\vec{x}) = 0.125 - x_1 \leq 0 \quad (3.15)$$

$$g_7(\vec{x}) = 0.10471x_1^2 + 0.04811 x_3 x_4(14 + x_2) - 5 \leq 0 \quad (3.16)$$

Burada,

$$T(\vec{x}) = \sqrt{(T')^2 + 2T'T'' \frac{x_2}{2R} + (T'')^2}, T' = \frac{P}{\sqrt{2} x_1 x_2}, T'' = \frac{MR}{J}, M = P(L + \frac{x_2}{2}),$$

$$R = \sqrt{\frac{x_2^2}{4} + (\frac{x_1+x_3}{2})^2},$$

$$J = 2 \left\{ \sqrt{2} x_1 x_2 \left[\frac{x_2^3}{4} + \frac{(x_1+x_3)^2}{2} \right] \right\}, \sigma(\vec{x}) = \frac{6PL}{x_4 x_3^2}, \delta(\vec{x}) = \frac{4PL^3}{Ex_4 x_3^2},$$

$$P_c(\vec{x}) = \frac{4.013E \sqrt{\frac{x_3^2 x_4^6}{36}}}{L^2} \left(1 - \frac{x_3}{2L} \sqrt{\frac{E}{4G}} \right)$$

olarak hesaplanır ve $P = 6000 \text{ lb}$, $L = 14 \text{ in}$, $G = 12 \times 10^6 \text{ psi}$, $T_{max} = 13600 \text{ psi}$ olarak alınır. Ayrıca, $\sigma_{max} = 30000 \text{ psi}$, $\delta_{max} = 0.25 \text{ in}$, $E = 30 \times 10^6 \text{ psi}$ 'dir. Deęişkenlerinin aralıkları ise ařaęıdaki gibi alınır:

$$0.1 \leq x_1 \leq 2 \quad (3.17)$$

$$0.1 \leq x_2 \leq 10 \quad (3.18)$$


$$0.1 \leq x_3 \leq 10 \quad (3.19)$$

$$0.1 \leq x_4 \leq 2 \quad (3.20)$$

c) Basınçlı Boru Tasarım Problemi

Basınçlı boru tasarım probleminde, basınçlı borunun minimum maliyetini bulmak amaçlanmaktadır. Kafa kalınlığı (T_h), kabuk kalınlığı (T_s), silindirik bölümün kafa uzunluğu (L) ve iç yarıçap (R) olmak üzere dört deęişken ele alınmaktadır. Basınçlı boru tasarım modeli Şekil 3.3'de verilmiştir. Probleme ait deęişkenler ařaęıdaki denklemlerde $\vec{x} = [x_1, x_2, x_3, x_4]$ olarak ifade edilen $[T_s, T_h, R, L]$ ' dir. Probleme ait maliyet fonksiyonu ařaęıdaki eřitlikte sunulmuřtur:

$$f_3(\vec{x}) = 0.6244x_1x_3x_4 + 1.7781x_2x_3^2 + 3.1661x_1^2x_4 + 19.84x_1^2x_1^2x_3 \quad (3.21)$$



Şekil 3.3. Basıncılı boru tasarım modeli

Dört değişken için kısıtlar ise Eş. (3.22) - (3.25)'de verilmiştir:

$$g_1(\vec{x}) = -x_1 + 0.0193x_3 \leq 0 \quad (3.22)$$

$$g_2(\vec{x}) = -x_2 + 0.00954x_3 \leq 0 \quad (3.23)$$

$$g_3(\vec{x}) = -\pi x_3^2 x_4 - \frac{4}{3}\pi x_3^3 + 1296000 \leq 0 \quad (3.24)$$

$$g_4(\vec{x}) = x_4 - 240 \leq 0 \quad (3.25)$$

Benzer şekilde, $[T_s, T_h, R, L]$ değişkenleri için aralıklar aşağıdaki eşitliklerde verilmiştir:

$$0 \leq x_1 \leq 99 \quad (3.26)$$

$$0 \leq x_2 \leq 99 \quad (3.27)$$

$$10 \leq x_3 \leq 200 \quad (3.28)$$

$$10 \leq x_4 \leq 200 \quad (3.29)$$

d) Üç Çubuklu Kafes Tasarım Problemi

Üç çubuklu kafes tasarım probleminin amacı, üç çubuklu bir kafes kirişin ağırlığını yapısal tasarım değişkeniyle en aza indirmektir. Şekil 3.4'deki kafes kirişin yapısından ve kuvvetlerinden kesit alanlarını ayarlamak için iki parametrenin belirlenmesi gerekir.

Problemin ait değişkenler $[A_1, A_2]$ aşağıdaki matematiksel ifadelerde $\vec{x} = [x_1, x_2]$ olarak alınmıştır. Kaynaklı kirişin maliyetini en aza indirmek amacıyla kullanılan fonksiyon aşağıdaki eşitlikte ifade edilmiştir:


$$f_3(\vec{x}) = (2\sqrt{2}x_1 + x_2) x l \quad (3.30)$$

Bu problemin değişkenleri için kısıtlar aşağıdaki eşitliklerde görülmektedir:

$$g_1(\vec{x}) = \frac{\sqrt{2}x_1 + x_2}{\sqrt{2}x_1^2 + 2x_1x_2} \leq 0 \quad (3.31)$$

$$g_2(\vec{x}) = \frac{x_2}{\sqrt{2}x_1^2 + 2x_1x_2} P - \sigma \leq 0 \quad (3.32)$$

$$g_3(\vec{x}) = \frac{x_2}{x_1 + \sqrt{2}x_2} P - \sigma \leq 0 \quad (3.33)$$



Şekil 3.4. Üç çubuklu kafes tasarım modeli

Burada, $L = 10\text{cm}$, $P = 2\text{KN/cm}^2$, $\sigma = 2\text{KN/cm}^2$ olarak alınır. Benzer şekilde, $[A_1, A_2]$ değişkenleri için aralıklar aşağıdaki eşitliklerde verilmiştir.

$$0 \leq x_1 \leq 1 \quad (3.34)$$

$$0 \leq x_2 \leq 1 \quad (3.35)$$

3.1.3. Berkeley-Benchmark Veri Seti (BSDS300)

Berkeley-Benchmark verisetinde, farklı karakteristiklere sahip 300 test görüntüsü bulunmaktadır [141]. 1000 Corel veri seti görüntüsünden 30 insan denek tarafından elle etiketlenmiş 12000 segmentasyon mevcuttur. Segmentasyonlar deneğe renkli ve gri tonlamalı görüntüler sunarak elde edilmiştir. Bu görsellere ait şekil-zemin etiketleri de mevcuttur. Her bir görüntüye ait farklı insan denekler tarafından bölütlenen beş-altı adet referans görüntü bulunmaktadır. Veri setinden alınan örnek görüntüler Şekil 3.5'te verilmiştir:




Şekil 3.5.BSDS300 verisetinden alınan örnek görüntüler

3.1.4. ISIC2017 Deri Kanseri Görüntüleri Veri Seti

Uluslararası Cilt Görüntüleme İşbirliği (International Skin Imaging Collaboration-ISIC) 2017 veri seti, toplam 2750 dermoskopi görüntüsünden oluşmaktadır [142]. Bu veri seti ile


dermoskopik görüntülerden melanomun otomatik teşhisini gerçekleştirmek amaçlanmıştır. Segmentasyon algoritmasının doğrulanması için kullanılan bu veri kümesinin temel gerçek örnekleri de halka açıktır. Görüntüler, melanom, seboreik keratoz ve nevüs olmak üzere üç kategoriye ayrılmıştır. 374 adet melanom, 254 adet seboreik keratoz ve 1372 adet nevüs görüntüsü mevcuttur. Verisetinden alınan örnek deri görüntüleri Şekil 3.6’da sunulmuştur:



Şekil 3.6. ISIC2017 verisetinden alınan örnek görüntüler

3.1.5. BIDC Göğüs Kanseri Görüntüleri Veri Seti


Dereceli Göğüs Invasiv Ductal Carcinom (Breast Invasive Ductal Carcinoma-BIDC) veri seti, 2014-2019 yılları arasında İsfahan Tıp Bilimleri Üniversitesi Anahid Kliniği ve Pour Sina Hakim Sindirim Hastalıkları Araştırma Merkezi hastanesinden toplanmıştır [143]. Veri setinde hastaların I, II ve III. derece patolojik biyopsi örnekleri bulunmaktadır. Veri setindeki patolojik görüntüler, 4x, 10x, 20x ve 40x şeklinde dört büyütme düzeyi kullanılarak elde edilmiştir. Invasiv Ductal Karsinoma’lı 124 hastaya ait toplam 922 görüntü mevcuttur. BIDC verisetinden alınan örnek göğüs kanseri görüntüleri Şekil 3.7’de gösterilmiştir:



Şekil 3.7.BIDC verisetinden alınan örnek görüntüler

3.1.6. DEAP-EEG Sinyalleri Veri Seti

Fizyolojik Sinyalleri Kullanarak Duygu Analizi için Veritabanı (Database for Emotion Analysis using Physiological Signals-DEAP), insanın duygusal durumlarının analizi için kullanılan çok modlu bir veri setidir [144]. 32 katılımcının elektroensefalogramı (EEG) ve periferik fizyolojik sinyalleri, her biri 40 adet birer dakikalık müzik videosu izledikçe kaydedilmiştir. Katılımcılar her videoyu uyarılma, değerlik, beğenme/beğenmeme, baskınlık ve aşinalık düzeylerine göre derecelendirmişlerdir. Örnek bir EEG sinyali görüntüsü Şekil 3.8’de sunulmuştur.



Şekil 3.8. DEAP verisetinden alınan örnek bir EEG sinyali görüntüsü

3.2. Çok Seviyeli Görüntü Eşikleme

Bu bölümde, çok seviyeli görüntü eşikleme performansının artırılmasına yönelik olarak geliştirilmiş olan yöntemlerin detaylarına yer verilmiştir. Görüntü eşikleme performansının başarımının artırılmasına yönelik olarak beş yöntem geliştirilmiştir. Bu yöntemler; Altın Sinüs Algoritması, Kaotik Karşıt Öğrenme Tabanlı Altın Sinüs Algoritması, Kaotik Olarak Zenginleştirilmiş Adaptif Rao Algoritması, Parçacık Sürü Optimizasyon Algoritması, Ziyaret Tablosu Stratejisine Dayalı PSO Algoritması'na dayalı çok seviyeli eşikleme algoritmalarıdır.

3.2.1. Altın Sinüs Algoritması


Görüntü eşikleme yöntemlerinde eşik seviyelerinin sayısı arttıkça artan hesaplama karmaşıklığı nedeniyle eşikleme oldukça zaman alan ve yorucu bir işlemdir. Bu bölümde, hesaplama süresini azaltmak ve eşikleme performansını iyileştirmek amacıyla GoldSa II yöntemine ve Renyi'nin entropisine dayalı yeni bir eşikleme yöntemi önerilmiştir. GoldSa II azalan sinüs fonksiyonu ve altın oranı kullanarak arama alanını daraltır ve hedeflenen optimum noktayı (optimum eşikler) daha kısa sürede daha doğru bir şekilde yakınsar. Çalışmada, ilk olarak iki boyutlu, yerel olmayan ortalama histogram oluşturulmuştur ve farklı eşikleme seviyelerine sahip gri seviyeli görüntülere bölütleme işlemi uygulanmıştır. Önerilen iki boyutlu, yerel olmayan ortalamalar histogramına ve Altın Sinüs II algoritmasına dayalı bölütleme yöntemi (non-local means Golden Sinus Algorithm II - NLM-GoldSa II) performans değerlendirmeleri 12 farklı görüntü kalitesi ölçüm indeksi kullanılarak gerçekleştirilmiştir. Bu indeksler; Sınır yer değiştirme hatası (Boundary Displacement Error-BDE), Bilgi varyasyonu (Variance of Information-VOI), Global tutarlılık hatası (Global Consistency Error-GCE), Olasılık rand endeksi (Probability Rand Index-PRI), Tepe sinyal gürültü oranı (Peak Signal to Noise Ratio-PSNR), Yapısal benzerlik indeksi (Structural Similarity-SSIM), Özellik benzerlik indeksi (Feature Similarity-FSIM) [136], Hatanın ortalama karekökü (Root Mean Squared Error-RMSE) [137], Çapraz korelasyon (Cross Correlation-CC) [137], Ortalama fark (Average difference-AD)[137], Maksimum fark (Maximum

Difference-MD) [137], Normalleştirilmiş mutlak hata (Normalized Absolute Error-NAE) [46])'dir. Deneyler Berkeley-Benchmark 300 (BSDS300) veri seti üzerinde yapılmıştır. Deneysel sonuçlar, hesaplama süreleri, uygunluk değerleri ve optimum eşik değerleri açısından Yapay Arı Algoritması (Artificial Bee Colony-ABC), DE, GSA, kaotik K_{best} GSA (chaotic K_{best} GSA - cKGSA), üstel K_{best} Yer Çekimi Arama Algoritması (exponential K_{best} GSA - eKGSA), ve PSO olmak üzere altı bölütleme yöntemiyle karşılaştırılarak sunulmuştur. 3-seviyeli ve 5-seviyeli eşikleme ile yapılan segmentasyonda, diğer segmentasyon yöntemlerine göre 12 kalite ölçüm indeksinden 7'sinin en iyi sonucu verdiği çalışmalardan görülmektedir. Belirtilen indekslerde; 3 seviyeli eşikleme için MD' de %5.4151, CC' de %33.11, RMSE' de %0.1011, FSIM' de %0.1618, VOI' de %0.6180, BDE' de %0.0615 ve PRI' da %0.4557 oranında iyileşme sağlanmıştır. 5 seviyeli eşikleme için NAE' de %1.3591, MD' de %3.2552, CC' de %17.6973, RMSE' de %0.2176, SSIM' de %0.1939, FSIM' de %0.02551 ve BDE' de %1.7236 oranında iyileşme sağlanmıştır. Ayrıca önerilen yöntemin diğer yöntemlere göre en yüksek uygunluk değerine ulaştığı ve bu durumda optimum eşik değerlerini diğer yöntemlerden daha iyi yakınsayarak daha başarılı bir bölütleme işlemi gerçekleştirdiğini göstermektedir. BSDS300 veri setinden rastgele alınan örnek görüntülerin bölütlenmesi, önerilen yönteme ek olarak diğer mevcut bölütleme yöntemleri kullanılarak gerçekleştirilmiştir ve önerilen yöntemin mevcut yöntemlere göre üstün sonuçlar ürettiği gözlemlenmiştir. Bu çalışmanın katkıları aşağıdaki gibi özetlenebilir:

- ✓ İki boyutlu bir NLM-GoldSa II çok seviyeli eşikleme yöntemi geliştirilmiştir.
- ✓ GoldSa II yöntemi güncel bir yöntem olup çok seviyeli eşikleme problemi üzerindeki davranışı ilk defa incelenmiştir.


Önerilen iki boyutlu NLM-GoldSa II Algoritması çok seviyeli eşikleme yöntemi, Renyi'nin entropisi kullanılarak gri seviyeli görüntülere uygulanmıştır. Önerilen yöntem, Şekil 3.9'da gösterilen akış şemasında özetlenmiştir, burada verilen orijinal renkli görüntüler gri seviyeli görüntülere dönüştürülür ve bir histogram elde edilir.

Histogramı, iki boyutlu NLM yöntemi kullanılarak elde edilen gri seviyeli görüntülerin eşik değerleri, Renyi'nin entropi yöntemi kullanılarak elde edilmiştir. Hesaplama süresini en aza indirmek için, GoldSa II optimizasyon yöntemi kullanılmıştır. Elde edilen optimum eşik değerleri ile bölütlenen görüntüler daha sonra referans görüntüler ile karşılaştırılmıştır. BDE, GCE, PRI, VOI, FSIM, BDE, AD, MD ve NAE olarak adlandırılan görüntü kalitesi ölçüm indeksleri kullanılarak segmente edilmiş görüntülerin performans değerlendirmeleri gerçekleştirilmiştir. $g(x, y)$ girdi görüntüsü $f(x, y)$ için yerel olmayan araçlarla filtrelenmiş bir görüntü olsun. h_{ij} ise $M \times N$ boyutlu ve L gri seviyeli görüntülerin, $g(x, y) = j$ ve $f(x, y) = i$ 'deki toplam piksel sayısı olsun. Bu durumda, iki boyutlu, yerel olmayan histogram $p_{ij} = h_{ij}/(M \times N)$ olarak hesaplanır. Burada, $i = \{0, 1, \dots, L\}$ ve $j = \{0, 1, \dots, L\}$ olarak alınır. Elde edilen $L \times L$ boyutlu histogram Şekil 3.10'da verilmiştir.



Şekil 3.9 İki boyutlu NLM-GoldSa II yöntemine dayalı görüntü bölütleme akış şeması.

İki boyutlu eşik vektörü, histogramı dört eşit parçaya ayırır. 2'inci ve 3'üncü kısımlar gürültü ve kenar bilgisini içerirken, 1'inci ve 4'üncü kısımlar sırasıyla ön plan ve arka plan bilgisini içermektedir. Bu bağlamda, yöntemin hedefi olan nesneleri arka plandan ayırmak için sadece köşegen kısımlar dikkate alınmaktadır.

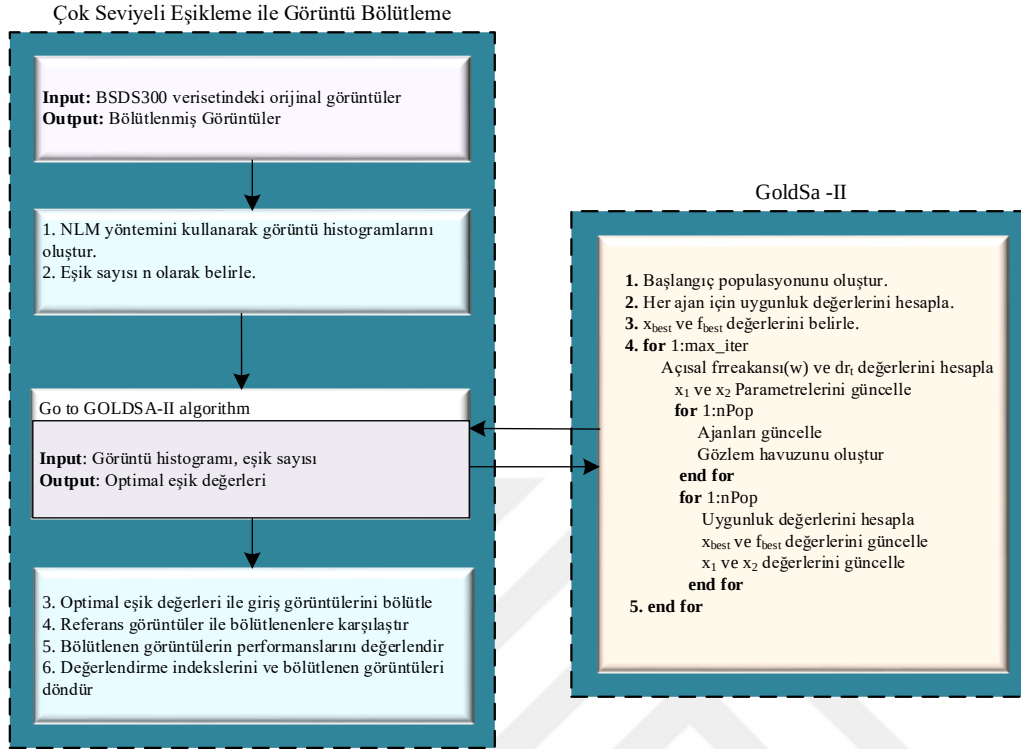


Şekil 3.10. İki boyutlu yerel olmayan ortalamalar histogramı

Optimum eşikler, iki boyutlu yerel olmayan ortalamalar yöntemiyle çıkarılan pij histogramını kullanılarak Renyi'nin yöntemine göre bulunur. Renyi'nin çok seviyeli eşikleme yöntemi Eş. (3.36)'daki gibi kolayca genişletilebilir.

$$\begin{aligned}
 H_0 &= \frac{1}{1-q} \ln \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} \left(\frac{p_{ij}}{p_0} \right)^q \\
 H_1 &= \frac{1}{1-q} \ln \sum_{i=s}^{s_1-1} \sum_{j=t}^{t_1-1} \left(\frac{p_{ij}}{p_B} \right)^q \\
 H_2 &= \frac{1}{1-q} \log \sum_{i=s_1}^{s_2-1} \sum_{j=t_1}^{t_2-1} \left(\frac{p_{ij}}{p_B} \right)^q \\
 &\vdots \\
 H_M &= \frac{1}{1-q} \log \sum_{i=s_1}^{L-1} \sum_{j=t_1}^{L-1} \left(\frac{p_{ij}}{p_B} \right)^q
 \end{aligned} \tag{3.36}$$

Algoritma 3.1. Renyi'nin entropisini kullanan önerilen iki boyutlu NLM-GoldSa II Algoritmasına dayalı görüntü bölütleme yöntemi sözde kodu.



M optimum eşik değerini belirlemek için, sınıf varyanslarının toplamı $T^* = Arg \max (\sum_{i=0}^M H_M)$ olarak maksimize edilir. Renyi'nin entropisini kullanarak geliştirilen iki boyutlu NLM-GoldSa II tabanlı görüntü bölütleme algoritması için sözde kod Algoritma 3.1'de sunulmuştur.

Algoritma 3.1' de giriş olarak orijinal görüntüler verilir çıkışta bölütlenmiş görüntüler elde edilmektedir. Orijinal görüntülerin histogramları, yerel olmayan 2D histogram yöntemi kullanılarak elde edilir. Girdi görüntüsünün kaç parçaya bölüneceğine göre eşik seviyesi belirlenir. Belirlenen eşik seviyesi ve oluşturulan histogram GoldSa-II yöntemine giriş olarak verilir. Goldsa-II yönteminde her bir ajan için uygunluk değerleri hesaplandıktan sonra en iyi uygunluk değerine sahip ajan belirlenir. Algoritmanın üçüncü adımındaki işlemler, maksimum iterasyon sayısına ulaşılan kadar tekrarlanır. Burada, açılal frekans değeri $w = 2\pi Fc$ formülü ile ve dr_t değeri $dr_t = 2 * \frac{1-t}{t_{max}}$ denklemi ile hesaplanmıştır. Bununla beraber, x_1 ve x_2 değerleri Eş. (2.2) ve (2.3) ile güncellenir. Yeni ajanların uygunluk değerleri hesaplanarak optimum ajan x_{best} ve bu ajanların uygunluk değerleri f_{best} olarak atanır. x_1 ve x_2 değerleri (a,b) aralıklarına göre tekrar güncellenir. Bu işlemler, maksimum iterasyon sayısına ulaşılan kadar tekrar edilir. Döngü sonunda elde edilen optimum eşik seviyeleri, Algoritma 3.1'e geri gönderilir. Giriş görüntüleri, elde edilen optimum eşik değerlerine göre bölütlenir. Parçalara ayrılmış görüntüler, veri setindeki referans görüntüler ile

karşılaştırılır ve bölütlenen görüntünün performansı, görüntü kalitesi ölçüm indeksleri ile değerlendirilir.

3.2.2. Kaotik Karşıt Öğrenme Tabanlı Altın Sinüs Algoritması

Pek çok mühendislik disiplininde zorlu problemlere en iyi çözümleri bulmak için optimizasyon tekniklerine ihtiyaç duyulmaktadır. Çeşitli evrimsel stratejiler kullanarak arama uzayını etkili bir şekilde artıran metasezgisel algoritmalar son yıllarda giderek daha popüler hale geldi. Altın Sinüs Algoritması (Golden Sinus Algorithm-GoldSa), sinüs fonksiyonu ve altın oranı kullanan popülasyon tabanlı bir optimizasyon algoritmasıdır. Bu çalışmada, GoldSa yönteminin keşif (exploration) ve sömürü (exploitation) yeteneklerinin verimliliğini artırmak için kaotik haritalarla zenginleştirilmiş karşıtlık tabanlı bir Altın Sinüs Algoritması (Chaotically enhanced opposition based GoldSa-CoGoldSa) önerilmiştir. Bu yaklaşımı tasarlarırken öncelikle GoldSa parametrelerinin kaotik davranışları analiz edilmiştir. Bu amaçla, kaotik haritaların farklı davranışa sahip parametreler üzerindeki etkisini belirlemek için sekiz kaotik harita kullanılarak kaotik olarak zenginleştirilmiş GoldSa (cGoldSa) yöntemleri geliştirilmiştir. İkinci olarak, karşıtlık temelli öğrenme stratejisi, etkin bir başlangıç popülasyonunun oluşturulması amacıyla cGoldSa'ya ilave edilmiştir. Önerilen Co-GoldSa yönteminin etkililiğini araştırmak için, kıyaslama fonksiyonları ve klasik mühendislik tasarım problemleri üzerinde iyi bilinen ve yeni tanıtılan meta-sezgisel yaklaşımlarla incelenmiştir. Ayrıca, göğüs kanserinin patolojik görüntülerin verimli bir şekilde işlenmesinin tıbbi teşhiste oldukça önemli olması nedeniyle, Co-GoldSa yöntemine dayalı olarak etkili bir görüntü bölütleme şeması sunulmuştur. Deneysel sonuçlar, önerilen yöntemin küresel optimizasyon problemleri, görüntü bölütleme ve mühendislik problemlerinin çözümü üzerindeki üstünlüğünü ortaya koymaktadır. Elde edilen deneysel sonuçlar, önerilen Co-GoldSa yaklaşımının zorlu optimizasyon problemlerinin çözümü için umut verici bir yöntem olarak kabul edilebileceğini desteklemektedir. Bu çalışmanın katkıları aşağıdaki gibi özetlenebilir:

- ✓ Doğrusal olarak azalan bir fonksiyon olan Altın Sinüs Algoritması (GoldSa) parametrelerinin kaotik davranışları sekiz kaotik harita kullanılarak incelenmiştir.
- ✓ Kaotik olarak geliştirilmiş GoldSa (cGoldSa)'da hem doğrusal olarak azalan hem de rastgele oluşturulan parametrelerin davranışları analiz edilmiştir.
- ✓ Önerilen üç cGoldSa yöntemi, ortalama, en iyi, en kötü ve standart sapmadan oluşan bir dizi istatistiksel test açısından sekiz kaotik harita kullanılarak kıyaslama fonksiyonları üzerinde değerlendirilmiştir.
- ✓ Geliştirilmiş cGoldSa'ya karşıtlığa dayalı öğrenme stratejisi eklenerek yönteminin arama yeteneğini ve başlangıç popülasyonunu geliştirmek amaçlanmıştır.
- ✓ Bu kapsamda, Co-GoldSa yöntemi geliştirilmiştir. Geliştirilen yöntem test fonksiyonlarına uygulanarak orijinal GoldSa ve cGoldSa yöntemleriyle karşılaştırılarak değerlendirilmiştir.

- ✓ GoldSa yönteminin keşif ve sömürü yeteneklerinin verimliliğini artırmak için kaotik haritalarla zenginleştirilmiş karşıtlık tabanlı bir Altın Sinüs Algoritması önerilmiştir.
- ✓ Kaotik haritaların farklı davranışa sahip parametreler üzerindeki etkisini belirlemek için sekiz kaotik harita kullanılarak kaotik GoldSa yöntemleri geliştirilmiştir.
- ✓ Başlangıç popülasyonunun etkinliğini artırmak amacıyla karşıtlık temelli öğrenme stratejisine dayalı Co-GoldSa yöntemi geliştirilmiştir.
- ✓ Önerilen Co-GoldSa yöntemi ayrıca klasik mühendislik tasarım problemlerinde iyi bilinen ve yeni tanıtılan metasezgisel yaklaşımlar olan MVO, MFO, WOA, AOA, AO, CO, RSA, GMO ve SAO ile karşılaştırılmıştır.
- ✓ Meme kanserinin patolojik görüntüleri için Co-GoldSa, Renyi'nin entropisi ve yerel olmayan ortalama 2D histogramına dayalı olarak Çok Düzeyli Eşikleme ile Görüntü Segmentasyonu (MTIS) çerçevesi geliştirilmiştir.
- ✓ Geliştirilen MTIS çerçevesi bu görüntüler için bahsedilen diğer meta-sezgisel algoritmalarla karşılaştırılmıştır. Segmentasyon sonuçları, yapısal benzerlik matrisi (SSIM), özellik benzerliği matrisi (FSIM) ve tepe-sinyal gürültü oranı (PSNR) olan görüntü kalitesi ölçüm indeksleri ile değerlendirilir.
- ✓ Benchmark fonksiyonları, mühendislik problemleri ve patolojik görüntülerin çok seviyeli eşiklenmesi üzerine yapılan deneysel çalışmalar, önerilen Co-GoldSa yönteminin diğer yöntemlere göre üstün olduğunu göstermektedir.
- ✓ Bu çalışma aynı zamanda klasik mühendislik problemleri ve çok düzeyli eşikleme görüntü bölütleme uygulamalarına yönelik iyi bilinen ve yeni tanıtılan meta-sezgisel yaklaşımların ayrıntılı bir karşılaştırmasını da içermektedir.

Bu kısım iki alt bölüme ayrılmıştır. Birinci kısımda öncelikle GoldSa yönteminde kaotik haritaların kullanımı anlatılmaktadır. Bu kapsamda sekiz kaotik haritanın davranışı incelenmiş ve üç GoldSa yöntemi geliştirilmiştir. 8 kaotik haritayla geliştirilen 3 cGoldSa yöntemlerinden en iyi kaotik haritayla en etkin cGoldSa yöntemi seçilir. İkinci olarak, algoritmanın başlangıç popülasyonunu en optimal yerden başlatabilmek için karşıtlık öğrenme stratejisi yönteme entegre edilmiştir. Belirtilen stratejilerin etkileri başlangıçta ayrı ayrı incelenmiş daha sonra her iki stratejinin algoritmaya entegre edildiği durumdaki etkinlikleri incelenmiştir. Kaotik güncelleme stratejisi ile GoldSa yönteminin keşif yeteneğini arttırmak amaçlanmaktadır. Karşıtlık temelli öğrenmeyi yönteme entegre ederek ise başlangıç popülasyonunu problem için en uygun yerden başlatabilmek ve optimum çözümün yakınsanmasında daha etkili olmasını sağlamak amaçlanmaktadır.

cGoldSa Yöntemleri:

GoldSa yönteminin ana faktörleri olan dr_t , r_1 ve r_2 parametreleri, yinelemeler boyunca hedef noktaya yaklaşmadan sorumludur. r_1 parametresi tüm bölgeyi ararken hareketin hedefe ne kadar

uzak olacağını belirler, r_2 parametresi ise mesafenin tanımlanmasında hedefin etkisini artırmak veya azaltmak için kullanılan bir ağırlık faktörüdür. dr_t fonksiyonu ise konumları güncellerken hareketin yönünü belirler. GoldSa algoritmasında r_1 ve r_2 parametreleri rastgele alınırken, önerilen yöntemde kaotik davranışın optimizasyon yöntemlerinin rastgele seçiminde daha iyi performans göstermesi nedeniyle kaotik olarak alınmaktadır. Ayrıca dr_t fonksiyonu doğrusal azalma yerine kaotik bir şekilde değişmektedir.

cGoldSa1: Güncelleme denklemindeki r_1 parametresi ilgili kaotik harita denklemi ile güncellenir. r_1 parametresi hedef çevresinde keşif ve sömürü için kullanılan bir parametredir. Tüm bölgeyi aramak için hareketin hedefe ne kadar uzak olacağını belirleyen keyfi bir değeri temsil eder. Önerilen kaotik GoldSa yönteminde r_1 parametresi rastgele adımlar yerine kaotik haritalar aracılığıyla üretilir. Bu, GoldSa yönteminde hedef noktayı daha hızlı ve daha kesin bir çözümle yakınsayan kaotik mekanizmayı temsil eder ve kaotik mekanizma yerel minimumlardan kaçır. r_1 parametresinin değerini elde etmek için sekiz farklı kaotik harita uyguluyoruz:

$$X_i^{t+1} = \begin{cases} X_i^t - dr_t * \sin(w * t * cr(t)) * (r_2 * x_1 D_p - x_2 * X_i^t), & r_3 < 0.5 \\ X_i^t + dr_t * \sin(w * t * cr(t)) * (r_2 * x_1 D_p - x_2 * X_i^t), & r_3 > 0.5 \end{cases} \quad (3.37)$$

Burada, X_i^{t+1} ifadesi $(i+1)$ 'inci iterasyondaki i 'inci noktayı temsil etmektedir. $r_1(t)$ ise t 'inci iterasyondaki kaotik harita ile üretilen değerdir.

cGoldSa2: Eş. (2.6)'nın r_2 parametresi rastgele bir değer almak yerine kaotik haritalar kullanılarak oluşturulmuştur. r_2 parametresi, hedefin mesafeyi belirlemedeki etkisini artırmak veya azaltmak için hedefe uygulanan rastgele bir ağırlık değeridir. r_2 parametresinin değerini elde etmek için farklı kaotik haritaları kullanıyoruz. Elde edilen r_2 değeri ile kaotik konum güncelleme denklemi şu şekilde hesaplanır:

$$X_i^{t+1} = \begin{cases} X_i^t - dr_t * \sin(w * t * r_1) * (cr(t) * x_1 D_p - x_2 * X_i^t), & r_3 < 0.5 \\ X_i^t + dr_t * \sin(w * t * r_1) * (cr(t) * x_1 D_p - x_2 * X_i^t), & r_3 > 0.5 \end{cases} \quad (3.38)$$

Burada, $r_2(t)$ t 'inci iterasyonda kaotik haritalar ile üretilen değerdir. X_i^{t+1} ifadesi $(t+1)$ 'inci i 'inci noktayı temsil eder.

cGoldSa3: Eş. (2.6)'nın dr_t parametresi kaotik harita denklemleri ile değiştirilmiştir. Algoritmada hareketin yönünü belirlemek için dr_t parametresi kullanılır. Doğrusal azalma yerine dr_t fonksiyonunun kaotik davranışından yararlanılmıştır. dr_t fonksiyonu, Denklem (3.4) aracılığıyla yinelemeler boyunca kaotik olarak değiştirilmektedir:

$$dr_t = cr * 2 * \left(\frac{1 - iter}{\max_iter} \right) \quad (3.39)$$

Burada, *iter* şimdiki iterasyon adımını ifade etmektedir. max_{iter} maksimum iterasyon sayısını göstermektedir.

Co-GoldSa Yöntemi:

Optimizasyon algoritmalarındaki en önemli sorun, arama uzayının başlangıçta uygun bir aralıkta başlatılamaması ve güncelleme aşamasında yetersiz keşif nedeniyle yerel optimuma takılıp küresel optimuma ulaşamamasıdır. Önerilen yöntemde GoldSa optimizasyon yönteminin güncelleme aşaması, çeşitliliği artıracak şekilde en iyi ve en uygun kaotik haritalarla zenginleştirilmiştir. Ayrıca en iyi aday çözümü kesin olarak belirlemek için karşıtlığa dayalı öğrenme (opposition-based learning-OBL) stratejisi GoldSa yöntemine dahil edilmiştir. OBL'yi temel alan kaotik GoldSa tekniği, başlangıç popülasyonunu oluştururken mevcut çözümün tersini de göz önünde bulundurarak arama uzayını genişletir. OBL mekanizmasının akış şeması Şekil 3.11'de görülmektedir.




Şekil 3.11. OBL stratejisi akış şeması

Bu çalışmada, tartışılan arama stratejilerini uygulayarak temel GoldSa'nın performansını artırmak için Co-GoldSa adı verilen yeni bir algoritma öneriyoruz. Önerilen Co-GoldSa yönteminin akış şeması Şekil 3.12'de gösterilmiştir. Şekil 3.12'de görüldüğü gibi, karşıtlık temelli stratejiye dayalı olarak başlangıç popülasyonu oluşturulur. İkinci adımda, seçilen kaotik haritanın davranışına göre kaotik terim hesaplanır. Üçüncü adımda, belirlenen cGoldSa yöntemine ilişkin r_1 , r_2 ve r_3 parametreleri atanır. Dördüncü adımda, (3.37-3.38) eşitlikleri kullanılarak popülasyon güncellenir. Arama ajanlarının uygunluk değerleri belirlenen maliyet fonksiyonu ile hesaplanır. Son adımda popülasyondan en iyi ajanlar seçilerek global optimum çözüm güncellenir. Belirtilen maksimum yinleme sayısına ulaşılan kadar döngü tekrarlanır. Önerilen yöntemin sözde kodu Algoritma 3.2'de ayrıntılı olarak verilmiştir.

Algoritma 3.2: Önerilen Co-GoldSa Yönteminin Sözde Kodu**Giriş:** Populasyon sayısı, maksimum iterasyon sayısı, problem boyutu, w , F_c , $gold$ **Çıkış:** Optimal çözüm

```
1. Başlangıç populasyonunu oluştur
2. Başlangıç populasyonunun zıt çözümlerini karıştılgıa dayalı öğrenme stratejisi ile hesapla
3. Karşıt çözümler daha iyi ise populasyonu güncelle
4.  $dr_t$ ,  $a$  ve  $b$ 'yi hesapla
5. for  $i=1:N$ 
6.   Her bir ajan için uygunluk değerlerini hesapla
7.   if  $X_i < FV$ 
8.      $FV = f(X_i)$ 
9.      $D_p = X_i$ 
10.  end
11. end
12. for  $i = 1:iter_{max}$ 
13.   Rastgele bir sayı oluştur ve  $z_t$  olarak ata
14.   Kaotik terimi ( $c_t$ ) hesapla ve ilgili parametreyi ( $r_1, r_2, dr_t$ ) kaotik terime göre güncelle
15.   for  $j=1:N$ 
16.      $r_1, r_2, r_3 \leftarrow rand(0,1)$ 
17.     Ajan değerlerini güncelle
18.   end
19.   for  $i=1:N$ 
20.     Yeni ajanların uygunluk değerlerini hesapla
21.     if  $f(X_i) < f(p_{best})$ 
22.        $p_{best} = X_i$ 
23.        $f(p_{best}) = f(X_i)$ 
24.     end
25.     if  $f(p_{best}) < f(g_{best})$ 
26.        $g_{best} = p_{best}, f(g_{best}) = f(p_{best})$ 
27.        $x_2 = b, x_2 = x_1,$ 
28.        $x_1 = a + (1-gold) * (b-a);$ 
29.     else
30.        $a = x_1, x_1 = x_2,$ 
31.        $x_2 = a + gold * (b-a);$ 
32.     end
33.     if  $x_1 == x_2$ 
34.        $a = -drt * rand;$ 
35.        $b = drt * rand;$ 
36.        $x_1 = a * (1-gold) + b*gold;$ 
37.        $x_2 = a*gold + b* (1-gold)$ 
38.     end
39.   end
40. end
```



Şekil 3.12. Önerilen Co-GoldSa yöntemi akış şeması

3.2.3. Kaotik Olarak Zenginleştirilmiş Adaptif Rao Algoritması

Çok seviyeli görüntü eşikleme, görüntü bölütleme için iyi bilinen bir tekniktir. Çok seviyeli görüntü bölütleme için eşik değerlerin belirlenmesinde meta sezgisel yöntemler kullanılmıştır. Mevcut meta sezgisel algoritmalar, metaforlara dayalıdır, oldukça karmaşıktır ve global optimumu hızlı bir şekilde yakınsamazlar. Bu çalışmada, metafor tabanlı algoritmalar yerine basit bir optimizasyon tekniği kullanarak eşikleme problemini basitleştiren çok seviyeli bir görüntü eşikleme yaklaşımı önerilmiştir. Daha spesifik olarak, önerilen yaklaşım, kaotik haritalama kullanılarak geliştirilmiş Rao algoritmasına dayanmaktadır. Böylece, çok seviyeli görüntü eşikleme için uyarlanabilir, kaotik olarak geliştirilmiş bir Rao (Chaotically Enhanced Rao-CER) algoritması geliştirilmiştir. Çok seviyeli görüntü eşiklemede Rao algoritmasını iyileştirmek için Logistic, Sine, Sinusoidal, Gauss, Circle, Chebyshev, Singer ve Tent olmak üzere sekiz farklı kaotik haritalama yaklaşımı kullanılmıştır. Önerilen yöntemin etkinliği 300 görüntü içeren BSDS300 veri seti üzerinde farklı metrikler kullanılarak değerlendirilmiş ve elde edilen sonuçlar literatürdeki mevcut çok seviyeli eşikleme yöntemleri ile karşılaştırılmıştır. Deneysel çalışmalarda, önerilen CER algoritması diğer yöntemlere kıyasla üstün sonuçlar üretmiştir. Ayrıca önerilen yöntem hız ve doğruluk açısından daha iyi yakınsama sağlamıştır. Bu çalışmanın katkıları aşağıdaki gibi özetlenebilir:

- ✓ Çok seviyeli görüntü eşikleme için uyarlanabilir, kaotik olarak geliştirilmiş bir Rao (Chaotically Enhanced Rao-CER) algoritması geliştirilmiştir.
- ✓ CER algoritmasına, Gri Seviye Eş Oluşum Matrisine ve Otsu'nun maksimum varyansına dayalı adaptif çok seviyeli bir görüntü segmentasyon yöntemi sunulmuştur.
- ✓ Her görüntü için bölütlenecek bölge sayısının ayırt edici olduğu belirlenmiştir ve literatürdeki pek çok çalışmadaki gibi veri kümesindeki tüm görüntüleri belirli bir sabit segment numarasına göre bölümlemek yerine, veri kümesindeki her görüntü için bölütlenecek bölge sayısını otomatik olarak bulan bir yöntem geliştirilmiştir.
- ✓ Önerilen yöntem, yakın zamanda yayınlanan ve basit matematiksel denklemlere dayanan Rao algoritmasına dayalı olarak geliştirilmiştir.
- ✓ Rao algoritmasındaki düzensiz rastgelelik yerine önerilen algorithmada kaotik davranıştan yararlanılmıştır.
- ✓ Çeşitli kaotik haritaların davranışları, Rao algoritmasının düzensiz rastgelelik sergileyen parametreleri üzerinde incelenmiştir.

Önerilen kaotik olarak geliştirilmiş Rao algoritmasında, düzensiz rastgelelik yerine fonksiyonun kaotik davranışı kullanılmıştır. Bu, hedef noktaya hızlı yakınsama ve daha kesin bir çözüm sağlayan Rao algoritması için kaotik bir mekanizmayı temsil etmektedir. Kaotik sistemler doğrusal olmayan ve ıraksak yapıları nedeniyle global optimuma ulaşmada yetkindirler [135]. CER algoritmasının sözde kodu Algoritma 3.3'de verilmiştir.

Önerilen CER algoritmasında, Rao algoritmasının performansını iyileştirmek için sekiz farklı kaotik harita kullanır. Kaotik haritalar ve formülleri Tablo 3.1'de görülmektedir. Önerilen yöntemde yeni aday çözümler şu şekilde hesaplanabilir:

$$x'_{j,k} = x_{j,k} + z_t(best_{j,i} - worst_{j,i}) \quad (3.40)$$

Önerilen $x'_{j,k}$, iterasyon boyunca değerlerini kaotik bir şekilde değiştirir. z_t parametresi, kaotik haritalarla elde edilen kaotik değeri temsil etmektedir. Kullanılan kaotik haritalardan biri olan lojistik harita için z_t :

$$z_{t+1} = \mu z_t (1 - z_t) \quad (3.41)$$

eşitliği ile güncellenmektedir. Burada, μ pozitif bir sabit ve kontrol parametresidir. z_t , t'inci iterasyondaki kaotik değerdir. Lojistik haritayı tamamen kaotik hale getirmek için μ değeri 4 olarak seçilmiştir. z değişkeni bu değerde daha iyi ergodikliğe sahiptir. Diğer kaotik haritaların eşitlikleri Tablo 3.1'de görülmektedir. Önerilen CER algoritmasında amaç fonksiyonu olarak 2D Otsu'nun eşikleme yöntemi kullanılmıştır. Algoritmanın parametrelerinin açıklamaları ve notasyonları Tablo 3.2'de gösterilmiştir.

Algoritma 3.3: Adaptif Çok Seviyeli Eşikleme için CER Algoritması	
Giriş: p, kaotikHarita, [ub, lb], max_iteration, max_level, pop, eps	
Çıkış: level, gbest, fgbest, error	
Adım 1: Başlangıç	
1: Başlangıç parametrelerini belirle 2: Kaotik haritayı seç	seviye=1,previous_fgbest=0,eps=0,max_level=50, max_iter=1000, d= level, n=20, 8 kaotik harita
Adım 2: Optimizasyon sürecini başlat	
3: while level < max_level 4: Populasyonu başlat 5: Uygunluk değerlerini hesapla	Popülasyon dxn boyutunda
Adım 3: Seçim	
6: gbest ve fgbest değerlerini belirle	
Adım 4: Populasyonu güncelle	
7: for i=1:max_iter 8: Çözümleri güncelle 9: Yeni çözümlerin uygunluk değerlerini hesapla	Tablo (3.1) ve Eş. (3.40)
Adım 5: Yeniden Seçim	
10: En iyi ve en kötü uygunluk değerlerini belirle 11: En iyi ve en kötü çözümleri belirle 12: if best_fitness > fgbest 13: best_fitness değişkenini fgbest olarak ata 14: best değişkenini gbest olarak ata 15: end if 16: end for	best_fitness & worst_fitness best & worst fgbest=best_fitness gbest=best
Adım 6: Bölüt seviyesini test et	
17: Hatayı hesapla 18: if hata < eps 19: break; 20: else 21: seviye sayısını artır	hata= fgbest – previous_fgbest seviye=seviye+1
Adım 7: previous_gbest ve previous_fgbest değerlerini güncelle	
22: fgbest değerini previous_fgbest olarak ata 23: gbest değerini previous_gbest olarak ata 24: endif 25. end while	previous_fgbest =fgbest previous_gbest=gbest
Adım 8: gbest ve fgbest değerlerini döndür	

Görüntüyü $f(x, y)$ olarak tanımlayalım. m-eşik değeri $\{T_1^*, T_2^*, \dots, T_m^*\}$ görüntüyü S_i olarak m+1 sınıflarına bölmektedir. Çok seviyeli eşiklemede $i = 1, 2, \dots, m+1$ dir.. S_1 ve S_{m+1} sırasıyla ön plan ve arka plan sınıflarıdır ve $S_i = 2, 3, \dots, m$ ara sınıflardır. Çok seviyeli eşikleme için, farklı sınıflar şu şekilde tanımlanabilir:

$$\begin{aligned}
S_1 &\in \{0, T_1 - 1\} \\
S_2 &\in \{t_1, T_2 - 1\} \\
S_3 &\in \{T_2, T_3 - 1\} \\
&\vdots \\
S_{m+1} &\in \{T_m, L - 1\}
\end{aligned} \tag{3.42}$$

Otsu'nun yöntemine göre, optimum eşik şu şekilde hesaplanabilir:

$$\{T_1^*, T_2^*, \dots, T_m^*\} = \arg \max(f_1, f_2, \dots, f_n) \tag{3.43}$$

Tablo 3.1. Çeşitli Kaotik Haritaların Matematiksel Formülleri


Kaotik harita	Formül
Logistic Harita	$z_{i+1} = \alpha z_i(1 - z_i), \alpha = 4$
Sine Harita	$z_{i+1} = \alpha \sin(\pi z_i), \alpha = 2.3$
Sinusoidal Harita	$z_{i+1} = \alpha z_i^2 \sin(\pi z_i)$
Gauss Harita	$z_{i+1} = \begin{cases} \frac{1}{\text{mod}(z_i, 1)}, & z_i \neq 0 \\ 1, & z_i = 0 \end{cases}$
Circle Harita	$z_{i+1} = z_i + a - \frac{b}{2\pi} \sin(2\pi z_i) \text{mod}(1), \quad a \in [0,1], \quad b \in [0,4\pi]$
Chebyshev Harita	$z_{i+1} = \cos(\cos^{-1}(z_i))$
Singer Harita	$z_{i+1} = \mu(-13,302875z_k^4 - 28,75z_k^3 - 23,31z_k^2 + 7,86z_k),$ $\mu \in [0.9 - 1.08]$
Tent Harita	$z_{i+1} = \begin{cases} \frac{z_i}{0.7} & z_i < 0.7 \\ \frac{10}{3}(1 - z_i) & z_i \geq 0.7 \end{cases}$

Eş. (3.8)'de görüldüğü gibi $\{T_1^*, T_2^*, \dots, T_m^*\}$ optimum çözüm kümesini çözmek için her aday çözümün uygunluk değeri ($fitness := \{f_1, f_2, \dots, f_n\}$) maksimize edilir ve f şu şekilde hesaplanabilir:

$$f := \sigma_o^2 + \sigma_1^2 + \dots + \sigma_m^2 \quad (3.44)$$

Önerilen görüntü bölütleme yönteminin blok diyagramı Şekil 3.13'te gösterilmektedir. Algoritmada, öncelikle önerilen yöntem için gerekli olan başlangıç parametrelerine karar verilir. Bu parametre değerleri ve açıklamaları Tablo 3.2'de verilmiştir. Burada maksimum iterasyon sayısı 1000 olarak alınmıştır. Eşik seviye sayısını adaptif olarak bulan algoritma için seçilen maksimum eşik seviye sayısı 50 olarak belirlenmiştir. Aday çözüm sayısı 20 olarak alınmıştır. Aday çözümlerin alt ve üst sınır değerleri sırasıyla 1 ve 255 olarak verilmiştir. Uygulanan tüm yöntemler için maksimum iterasyon sayısı, maksimum eşik seviye sayısı, popülasyondaki aday çözümlerin alt ve üst sınır değerleri ve aday çözüm sayısı aynı alınmıştır.

Basit optimizasyon tekniklerini kullanan Rao algoritması, optimum eşik değerlerini bulmak için kullanılır. Kaotik teori, optimizasyon problemlerinde düzensiz rastgeleliğe göre daha ergonomik ve avantajlı olduğundan, çok seviyeli eşiklemede optimum değerleri bulmak için kaotik olarak zenginleştirilmiş Rao (CER) algoritması geliştirilmiştir. Literatürde önerilen birçok kaotik harita vardır ve bunlardan en yaygın olanı vurgulanmıştır.



Şekil 3.13. Önerilen yöntemin akış diagramı

Çok seviyeli görüntü eşiklemede hangi kaotik haritanın daha başarılı olduğunu belirlemek ve Rao algoritmasının görüntü bölütlemedeki performansını iyileştirmek için önerilen yönteme Tablo 3.2'de formülleri verilen sekiz farklı kaotik harita uygulanmıştır. Bu amaçla daha önce de belirtildiği gibi Logistic, Sine, Sinusoidal, Gauss, Circle, Chebyshev, Singer ve Tent kaotik haritalama yöntemleri kullanılmıştır. Eşitlik (3.40)'ta verilen aday çözüm güncelleme denklemindeki z_t değeri, seçilen kaotik haritanın denklemine ve kaotik olarak güncellenen aday çözümlerin yeni değerlerine göre belirlenir. Tüm başlangıç parametreleri ve seçimler yapıldıktan sonra BSDS300 veri setinden seçilen görüntüler sırayla okunarak GLCM yöntemi kullanılarak 2D

histogramlar elde edilir. Önerilen CER algoritması ile her görüntünün eşik sayısı ve eşik değerleri elde edilir. Görüntüler, eşik sayısı ve eşik değerlerine göre segmentlere ayrılır. BSDS300 veri setinde farklı kişiler tarafından oluşturulan referans görüntüler, bölütlenmiş görüntülerle karşılaştırılır. Veri setinden rastgele seçilen birkaç örnek görüntünün referans görüntüleri Şekil 3.14’te verilmiştir.

Test Görüntü No	Referans Görüntüler
1	
2	
3	
4	
5	

Şekil 3.14. Seçilen test görüntülerinin referans görüntüleri

Şekil 3.14’te görüldüğü gibi, her görüntü için farklı bölütleme sayıları ve değerleri kullanılarak beş farklı kişi tarafından bölütleme yapılmıştır.

Tablo 3.2. Algoritma parametrelerinin gösterimleri ve tanımları

Tanım	Notasyon	Değer
Maksimum iterasyon sayısı	max_iteration	1000
Alt limit	Lb	1
Üst limit	Ub	255
Populasyon boyutu	Pop	20
Hatanın minimum değeri	Eps	0
Maksimum eşik seviye sayısı	max_level	50
Kontrol parametresi (kaotik haritalar)	α	
GLCM ile oluşturulan histogram	P	
Eşik sayısı	Level	
En iyi çözüm	global_best_sol	
En iyi çözümün uygunluk değeri	global_best_fitness	

Bölütleme performansı, en yaygın olarak kullanılan 12 indeks ile her görüntü için ayrı ayrı değerlendirilir. Kaotik haritaların birbirleri arasındaki avantajları ve önerilen çok seviyeli görüntü bölütleme yönteminin başarımı ve var olan diğer yöntemler (DE, ABC, GSA, cGSA ve eKGSA) ile karşılaştırmaları aşağıdaki bölümde verilmiştir.

3.2.4. Parçacık Sürü Optimizasyon Algoritması

Görüntü bölütleme, görüntü işlemenin en temel ve en önemli adımlarından biri olarak görülür. Görüntü bölütleme tekniklerinin çoğu, piksel yoğunluk değerlerine dayalı benzerlik yaklaşımını kullanır. Bölütleme görüntünün nesneleri arasındaki benzerliği kullanır. Bazı popüler benzerlik yaklaşımları eşikleme, bölge büyütme, bölge ayırma ve birleştirmedir. Eşikleme, bir dizi gri düzey eşik değeri kullanarak görüntüyü farklı bölgelere ayırır. Yalnızca bir gri seviye eşik değeri varsa, o zaman görüntü iki bölgeye bölünür, bu iki seviyeli eşikleme ifadesi eder. Çok seviyeli eşikleme, görüntüyü farklı alt bölgelere bölmek için birden fazla gri düzey eşik değerinin kullanıldığı iki seviyeli eşiklemenin genişletilmiş halidir. Literatürde bir görüntünün histogramını kullanan en yaygın tek boyutlu eşikleme yöntemlerinden bazıları Otsu'nun yöntemi [7], Kapur entropisi [6], Tsallis entropisi [145], [146], Rényi entropisi [147], [148] ve Masi entropisi [149]'dir.

Çok seviyeli eşikleme, bölütleme için temel bir yaklaşım olup son yıllarda çok popüler hale gelmiştir ancak eşiklerin seviyesi arttıkça, hesaplama karmaşıklığı da katlanarak artmaktadır. Bu dezavantajın üstesinden gelerek optimum eşik değerlerini belirlemek için çeşitli meta-sezgisel tabanlı algoritmalar kullanılmıştır. PSO algoritması uygulaması basit ve kolay anlaşılabilir bir algoritma olup global optimumu yakınsaması hızlıdır. Bu kapsamda, yerel olmayan ortlamalar histogramı ve PSO (2DYOHO-PSO) temelinde çok seviyeli bir eşikleme yöntemi önerilmiştir. Çalışmada, 2DYOHO-PSO, Berkeley-Beckmark Segmentation Dataset 300 (BSDS300) verisetindeki görüntülere uygulanmıştır. Algoritmanın arama yeteneği, görüntü bölütleme için Renyi'nin eşikleme yöntemi amaç fonksiyonu ile birleştirilmiştir.

Yöntemin başarımı, 12 adet ölçüm indeksi (Sınır yer değiştirme hatası (BDE), Olasılık rand indeksi (PRI), Bilgi varyasyonu (VOI), Global tutarlılık hatası (GCE), Yapılandırılmış benzerlik indeksi (SSIM), Özellik benzerlik indeksi (FSIM), Tepe sinyal-gürültü oranı (PSNR), Hatanın Ortalama Karekökü (RMSE), NAE, Ortalama fark (AD), Maksimum fark (MD)) kullanılarak belirlenmiştir. Önerilen yaklaşım, farklı eşik seviyelerinde DE, ABC, GSA, KGSA, cKGSA gibi mevcut gelişmiş optimizasyon algoritmalarına dayalı olarak geliştirilen çok seviyeli eşikleme yöntemleriyle karşılaştırılmıştır. Veri setindeki 300 görüntünün 3-seviyeli ve 5-seviyeli bölütlemeleri gerçekleştirilmiştir. 3-seviyeli bölütleme için BDE %2.63, PRI %0.83, SSIM %15.5, RMSE %13.2, PSNR %8.63, CC %35, AD %13.9, MD %14.75, NAE %10 oranında başarımlar sağlanmıştır. 5-seviyeli bölütlemelerde ise BDE %1, VOI %1.4, SSIM % 1.3, FSIM % 0.66, RMSE %0.46, PSNR %0.46, CC %21.69, AD %0.84 olarak başarımlar sağlanmıştır.

Deneyisel çalışmalarda, önerilen yöntem 12 farklı kalite ölçüm endeksinde oldukça başarılı olan yukarıda belirtilen beş yöntem ile karşılaştırılmıştır ve bu yöntemlere göre daha başarılı ve etkin bir bölütleme sağlandığı deneysel sonuçlarda görülmüştür. Bu yöntem için, f giriş görüntüsü ele alalım. Bu görüntünün yerel olmayan ortalamalar ile filtrelenmiş görüntüsü g olsun ve $M \times N$ boyutlarındaki L gri seviyeli görüntünün $f(x,y)=i$ ve $g(x,y)=j$ deki toplam piksel sayısı h_{ij} olsun. Bu durumda, iki boyutlu yerel olmayan histogram,

$$p_{ij} = \frac{h_{ij}}{M \times N} \quad (3.45)$$

olarak tanımlanabilir. Burada p_{ij} 'deki $i=\{0,1,\dots,L\}$ ve $j=\{0,1,\dots,L\}$ 'dir. İki boyutlu olarak alınan eşik vektörü, histogramı 4 eşit parçaya ayırır (Şekil 3.10). Nesne ve arka plan bilgisi, sırasıyla Bölge 1 ve Bölge 4' te bulunmaktadır. Gürültü ve kenar bilgisi Bölge 2 ve Bölge 3'te mevcuttur. Önerilen yöntem ile nesnelerin arka plandan ayrılması amaçlanmıştır. Bu amaçla, histogramın sadece diagonal bölgeleri alınarak işlemler gerçekleştirilmiştir. Görüntü, m adet eşik değeri ile m sınıfa ayrılmış olsun. Gri seviye sınıfları:

$$\begin{aligned} S_1 &= [0, \dots, t_1 - 1] \\ S_2 &= [0, \dots, t_2 - 1] \\ &\vdots \\ S_m &= [0, \dots, t_m - 1] \end{aligned} \quad (3.46)$$

ile elde edilir. t_m ifadesi m^{nci} eşik değerini gösterir. s_m ise m -gri seviye sınıfını temsil etmektedir.

Renyi'nin yöntemine göre sınıf etropileri Eş. (3.47)'de verilen eşitlikler kullanılarak tek tek bulunur.

$$\begin{aligned}
H_0 &= \frac{1}{1-q} \ln \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} \left(\frac{p_{ij}}{p_0}\right)^q \\
H_1 &= \frac{1}{1-q} \ln \sum_{i=s}^{s_1-1} \sum_{j=t}^{t_1-1} \left(\frac{p_{ij}}{p_B}\right)^q \\
H_2 &= \frac{1}{1-q} \log \sum_{i=s_1}^{s_2-1} \sum_{j=t_1}^{t_2-1} \left(\frac{p_{ij}}{p_B}\right)^q \\
&\vdots \\
H_M &= \frac{1}{1-q} \log \sum_{i=s_1}^{L-1} \sum_{j=t_1}^{L-1} \left(\frac{p_{ij}}{p_B}\right)^q
\end{aligned} \tag{3.47}$$

Her sınıf için elde edilen entropi değerleri toplanır ve Eş. (3.48) kullanılarak Renyi'nin toplam entropisi hesaplanır:


$$H = \sum_{i=0}^m H_i \tag{3.48}$$

Optimum eşik değerleri entropinin maksimum olduğu noktada bulunmaktadır ve Eş. (3.49) ile elde edilmektedir.

$$T^* = Arg \max(H) \tag{3.49}$$

Algoritma 3.4. Önerilen Yöntemin Sözde Kodu
Giriş: Veri seti içerisindeki görüntüler ($f^1, f^2, f^3, \dots, f^{300}$)
Çıkış: 12 kalite ölçüm indeksi, bölütlenen görüntüler ($g^1, g^2, g^3, \dots, g^{300}$)
1: Başlangıç çözümünü oluştur
2: Başlangıç parametreleri tanımla.
3: for görüntü sayısı
a. Eş. (3.10) kullanarak her bir f^n görüntüsünün histogramını hesapla
b. Bölütlenecek giriş görüntüsü f^n için eşik seviye sayısını belirle
c. Görüntü histogramını ve eşik seviye sayısını optimizasyon algoritmasına gönder
d. Başlangıç algoritma parametreleri olan atalet faktörü (w), hızlandırma faktörleri (c_1, c_2), popülasyondaki parçacık sayısı (N), iterasyon sayısı değerlerini belirle.
e. D-boyutlu arama uzayında başlangıç popülasyonunu oluştur $P = \{X_1, X_2, X_3, \dots, X_N\}$
f. for maksimum iterasyon sayısı
i. Her bir X parçacığının uygunluk değerini, Renyi'nin Entropi yöntemine göre hesapla
ii. En iyi yerel değerlerini- p_{best} , önceki p_{best} değerleri ile karşılaştırarak güncelle.
iii. Partiküllerin lokal en iyi pozisyonlarını birbirleri ile karşılaştırdır ve en iyi p_{best} değerini küresel en iyi g_{best} olarak ata. Her iterasyonda g_{best} değerini güncelle.
iv. Parçacıkların hız ve pozisyonlarını Eş. (2.8) ve Eş. (2.9)' u kullanarak güncelle.
g. end for
h. Bulunan eşik değerleri giriş görüntüsüne uygula.
ı. Bulunan optimum eşik değerini ve eşik değerine ait maksimum entropiyi sakla.
4: end for
5: Eşik değerleri giriş görüntüsüne uygula.
6: Bölütlenen görüntüleri veri setinde bulunan referans görüntüler ile karşılaştırdır.
7: Belirli kalite ölçüm indeksleri kullanarak bölütlenen görüntünün başarımını değerlendir.
8: Return kalite ölçüm değerleri ve bölütlenen görüntüler

Önerilen yöntemin sözde kodu ve akış şeması sırasıyla Algoritma 3.4 ve Şekil 3.15’ de sunulmuştur. Şekil 3.15’te verilen akış şemasında da görüleceği üzere ilk adımda giriş görüntüsü gri seviyeye dönüştürülür. İkinci adımda, gri seviyeli görüntünün histogramı, 2 boyutlu yerel olmayan ortalamalar histogramı yöntemi kullanılarak çıkartılır. 3.adımda giriş görüntüsü ve görüntüye ait histogram çok seviyeli eşikleme yönteminde giriş olarak alınır. Burada amaç fonksiyonu olarak Renyi’nin entropisi kullanılmaktadır.



Şekil 3.15. 2D-YOH yöntemi akış şeması

Yukarıdada belirtildiği gibi entropinin maksimum olduğu yerde optimum eşik değerleri bulunmaktadır. Bu amaçla maksimum entropiye ulaşana kadar ve algoritma için verilen iterasyon sayısına ulaşana kadar aday çözümler optimizasyon algoritması tarafından üretilir. Maksimum iterasyon sayısına ulaşıldığında, o zamana kadar üretilen tüm aday çözümlerin içinde entropinin maksimum olduğu nokta global optimum olarak belirlenir ve optimum eşik değeri olarak atanır. Elde edilen optimum eşik değerlerini kullanarak görüntü bölütlenir. Bölütlenen görüntü veriseti içerisinde bulunan referans görüntüler ile kıyaslanarak başarımları araştırılır. Çeşitli görüntü kalitesi ölçüm indeksleri ile bölütleme işleminin performansı değerlendirilir.

3.2.5. Ziyaret Tablosu Stratejisine Dayalı PSO Yöntemi

Deri hücrelerinde gelişen cilt kanseri, genellikle güneşten veya bronzlaşma yatakları gibi diğer kaynaklardan gelen ultraviyole (UV) radyasyona maruz kalma sonucu oluşur. Erken cilt kanseri tespiti hayat kurtarabilir ve ayrıca büyük tedavi maliyetlerinin önüne geçebilir. Manuel tarama, zaman alan, sıkıcı ve insan hatalarına açık bir işlemdir. Bu nedenle, cilt uzmanlarına cilt lezyonlarını erken bir aşamada doğru bir şekilde tespit etmede yardımcı olmak için otomatik tarama kullanılır. Çok seviyeli eşikleme, cilt kanseri görüntülerinin sınıflandırılmasını geliştirmek için yaygın olarak kullanılan ve etkili bir tekniktir. Bu çalışma, cilt kanseri görüntülerinde çok seviyeli eşikleme gerçekleştirmek için bir ziyaret tablosu stratejisi (PS-VTS) optimizasyon yöntemine sahip bir parçacık sürüsü önermektedir. Orijinal PSO'nun verimli ve geliştirilmiş bir versiyonu olan PS-VTS yöntemi, orijinal PSO yönteminin birkaç dezavantajını çözmek için geliştirilmiştir. İlk olarak algoritmaya ziyaret tablosu stratejisi eklenerek gereksiz aramaların önüne geçilmesi amaçlanmaktadır. İkinci olarak, yerel optimuma takılmayı önlemek için yeni bir hareket denklemi sunulmaktadır. Deneylerde yöntem iki farklı veri setine uygulanmıştır. İlk deneyler, farklı özelliklere sahip 50 kıyaslama problemi üzerinde gerçekleştirilmiştir. Önerilen yöntemin nicel ve nitel analizine ek olarak ölçeklenebilirlik analizi de yapılmıştır. Deneysel sonuçlar diğer yedi meta sezgisel yöntemle karşılaştırılmıştır. Bunlar: AOA (Aritmetik Optimizasyon Algoritması), GWO (Grey Wolf Optimization), MFO, WOA, MVO, TLBO (Teaching Learning Based Optimization) ve orijinal PSO. Sonuçlar, test fonksiyonlarının çoğu için PS-VTS optimizasyon yönteminin orijinal PSO'dan ve diğer son teknoloji yöntemlerden daha iyi olduğunu göstermiştir. İkinci olarak, Renyi'nin entropisi ve yerel olmayan ortalamalar 2D histogramı kullanılarak geliştirilen PS-VTS optimizasyon algoritmasına dayalı çok seviyeli bir eşikleme yöntemi önerilmiştir. Segmentasyonun deneysel sonuçları, önerilen yaklaşımın SSIM, FSIM ve PSNR görüntü kalitesi metrikleri açısından diğer algoritmalarından daha iyi olduğunu göstermektedir.

Önerilen yöntem farklı alanlarda görüntü bölütleme ve çeşitli medikal görüntü teşhislerinde uygulanabilir. Ayrıca, meta sezgisel algoritmaların performansını iyileştirmek ve gereksiz aramaların önüne geçmek için farklı ziyaret tablosu stratejileri de geliştirilebilir. Bu çalışmanın katkıları aşağıdaki gibi özetlenebilir:

- ✓ Sık ziyaret edilen noktalara ve bu noktaların komşularına daha az ziyaret yapılmasıyla yeni noktaların keşfedilmesine olanak tanıyarak PSO algoritmasının gereksiz aramalarını önleyen bir ziyaret tablosu stratejisi ve çok yönlü bir arama stratejisi algoritmaya entegre edilmiştir.
- ✓ Renyi'nin entropisi ve yerel olmayan ortalamalar 2D histogramı kullanılarak geliştirilen PS-VTS optimizasyon algoritmasına dayalı çok seviyeli bir eşikleme yöntemi önerilmiştir.
- ✓ Aynı zamanda çok seviyeli eşikleme görüntü bölütleme uygulamaları ve kıyaslama sorunları için iyi bilinen meta-sezgisel yaklaşımların niceliksel, niteliksel ve ölçeklenebilirlik analizleriyle ayrıntılı bir analizini sunmaktadır.

Optimizasyon probleminin temel amacı, problem için tanımlanan arama uzayında en kısa sürede optimum çözümü elde etmektir. PSO algoritması geliştirilen en eski algoritmalarından biri olmasına rağmen basit yapısı, kolay anlaşılır ve uygulanabilir olması nedeniyle günümüzde hala en sık kullanılan yöntemlerden biridir. Ancak bazı dezavantajlarından dolayı her problemde doğru sonucu (global optimum) bulamayabilmektedir [150]. Çeşitli optimizasyon problemlerinin çözümü için her gün yeni algoritmalar ve yeni arama stratejileri önerilmektedir. Bu yöntemlerden bazıları iyi olmasa da önerilen arama stratejileri farklı yöntemlere uygulandığında çok verimli sonuçlar alınabilmektedir. AHA (Artificial Hummingbird Algorithm) şimdiye kadar önerilen en güçlü algoritmalarından biridir ve algoritma için önerilen arama stratejileri diğer algoritmaların geliştirilmesine de ışık tutacaktır. PSO algoritması ve benzeri birçok algoritmada optimum çözüm aranırken daha önce ziyaret edilen aday çözümler tekrar tekrar ziyaret edilir. Bu, optimizasyon amacının aksine gereksiz işlem yüküne neden olur, optimumu yakınsama süresini uzatır ve de farklı noktaların keşfedilmesini engeller. Bu durum, parçacıkların farklı noktaları keşfetmek yerine sürekli aynı noktalara gitmesine neden olmakta ve yerel optimuma takılıp global optimuma ulaşmalarını engelleyebilmektedir. Ziyaret tablosu stratejisi ile parçacıkların önce ziyaret edilmeyen yerlere gitmesini sağlanarak daha erken zamanda farklı noktaları keşfedilmesini amaçlanmaktadır.

Matematiksel Model ve Algoritma:

Bu bölüm, önerilen PS-VTS algoritmasının ayrıntılarını sunmaktadır. Önerilen yöntemin sözde kodu Algoritma 1'de verilmiştir. Aşağıda ilgili bölümler ayrıntılı olarak açıklanmıştır.

Başlangıç popülasyonunun oluşturulması: PS-VTS, diğer tüm optimizasyon algoritmaları gibi rastgele bir popülasyonla başlar. İlk popülasyon:

$$x = x_{low} + r.(x_{up} - x_{low}) \quad (3.50)$$

eşitliği kullanılarak oluşturulur. Burada x, rasgele oluşturulan başlangıç popülasyonunu temsil etmektedir. r ifadesi; (0, 1) aralığında bir rasgele sayıyı temsil eder. PS-VTS yönteminde parçacıklar arama ajanlarıdır ve her parçacık bir aday çözüm olarak kabul edilir. Arama araçları yinelemeler sırasında güncellenir. Parçacıkların konum matrisi ve bunlara karşılık gelen uygunluk değerleri;

$$x = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1d} \\ x_{21} & x_{22} & \dots & x_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nd} \end{bmatrix} \quad f(x) = \begin{bmatrix} f(x_{11}, x_{12}, \dots, x_{1d}) \\ f(x_{21}, x_{22}, \dots, x_{2d}) \\ \vdots \\ f(x_{n1}, x_{n2}, \dots, x_{nd}) \end{bmatrix} \quad (3.51)$$

olarak hesaplanır. Burada, n popülasyondaki parçacık sayısını temsil eder. D, boyutunu temsil eder.

$f(x)$ uygunluk değerlerini gösterir. Ziyaret tablosu başlangıçta aşağıdaki gibi oluşturulur:

$$VT_{ij} = \begin{cases} NaN & \text{if } i = j \\ 0 & \text{else} \end{cases} \quad (3.52)$$

Eş. (3.52)'e göre $i=j$ durumunda parçacık ilgili kaynaktan besin alır ve ziyaret tablosu $VT_{ij} = NaN$ olarak atanır. i^{th} parçacık kaynağı ziyaret ettiğinde, ziyaret tablosu $VT_{ij} = 0$ olacaktır.

Parçacıkların konum ve pozisyonlarının güncellenmesi: Parçacıkların sürekli olarak aynı noktalara gitmesini engelleyerek farklı noktaların keşfedilmesini sağlamak ve global optimumu daha iyi yakınsamak için PSO'ya bir ziyaret tablosu stratejisi eklenmiştir. Buna göre PSO algoritmasındaki hız ve konum denklemleri:

$$v_i(k+1) = v_i(k) + C_1 \cdot \text{rand.} (x_{TL}(k) - x_i(k)) + C_2 \cdot (p_{best} - x_i(k)) \quad (3.53)$$

$$x_i(k+1) = x_i(k) + v_i(k+1) \quad (3.54)$$

şeklinde yeniden düzenlenmiştir. Burada $v_i(k)$ ve $v_i(k+1)$ sırasıyla mevcut ve sonraki hızları temsil eder. Benzer şekilde $x_i(k)$ ve $x_i(k+1)$ mevcut ve sonraki konumları temsil eder. C , PSO'nun ivme faktörüdür. rand ifadesi (0,1) aralığındaki rasgele sayıdır. $x_{TL}(k)$, en yüksek ziyaret düzeyine sahip bireydir. p_{best} , lokal en iyi uygunluk değerini temsil eder.


Ziyaret tablosunda ziyaret edilen her noktanın değeri sıfır olarak atanır ve ziyaret edilmeyen noktaların değerleri bir artırılır. Sürüyü yönlendirirken öncelik sürüyü hiç gidilmemiş yerlere veya en az ziyaret edilen noktalara yönlendirmektir. Ziyaret tablosundaki maksimum değere sahip noktalar, sürünün öncelikli olarak ziyaret edeceği kaynakların konumlarını gösterir. Şekil 3.16 ve Eşitlik (3.53)-(3.54) eşitlikleri, ziyaret tablosu stratejisine göre parçacıkların konumunun nasıl güncelleneceğini gösterir. Burada, beş parçacık için konum güncellemeleri ve ziyaret tablosu değişiklikleri gözlemlenmiştir. Ziyaret tablosu başlangıçta (3.52) numaralı eşitliğe göre oluşturulur. Oluşturulan ziyaret tablosuna göre n 'inci parçacık için hedef indeks belirlenir. Örneğin 1. parçacığı bakarsak hedef indeks 2 olduğu için konumu 2. parçacığın konumuna göre güncellenir (Eş. (3.53) – (3.54)). Elde edilen yeni çözümün uygunluk değeri bir öncekinden daha iyi ise yeni çözüm eskisinin yerini alır, aksi halde eski konumunu korur. Bu doğrultuda ziyaret tablosundaki ziyaret seviyelerine göre beş parçacığın her biri için konum güncellemesi yapılır. Her güncellemede ziyaret tablosundaki ziyaret edilen değere sıfır atanır ve ziyaret edilmeyen noktaların değerleri bir artırılır.

İkinci olarak, çeşitliliği artırmak için parçacıkların konumları, bulundukları yerden farklı yönlerde uçacak şekilde belirlenir. Bu nedenle, hız ve konum denklemleri aşağıdaki gibi yeniden düzenlenir:

$$v_i(k+1) = v_i(k) + \text{rand.} D. x_i(k) \quad (3.55)$$

$$x_i(k+1) = x_i(k) + v_i(k+1) \quad (3.56)$$

burada $v_i(k)$ ve $v_i(k + 1)$ sırasıyla mevcut ve sonraki hızları temsil eder. Benzer $x_i(k)$ ve $x_i(k + 1)$ mevcut ve sonraki konumları temsil eder. C, PSO'nun ivme faktörüdür. rand ifadesi (0,1) aralığındaki rasgele sayıdır ve D yön vektörünü ifade eder [151].



Şekil 3.16. Önerilen yöntem ile parçacıkların konumunun güncellenmesi.

Sonlandırma koşullarının kontrol edilmesi: Optimizasyon işlemi, yineleme sayısı maksimuma ulaşana kadar devam eder. Yenileme sayısı maksimuma ulaştığında döngü sonlandırılarak global optimum değeri döndürülür.

PS-VTS Yöntemi için Kullanılan İşlem Adımları:

Önerilen PS-VTS yönteminin ana süreci bu bölümde açıklanmaktadır. Önerilen PS-VTS yönteminin sözde kodu ve akış şeması sırasıyla Algoritma 3.5 ve Şekil 3.17'de gösterilmektedir.

Adım 1: Başlatma

Algoritma parametreleri (maksimum iterasyon sayısı için 1000, popülasyon büyüklüğü için 20, çalıştırma sayısı için 30, Eşik değeri için 0.5, ivme faktörleri(c_1 - c_2) için 0.6-1.2, atalet momenti için 0.8) atanır. Parçacıkların başlangıç konumları ve hızları, arama alanı aralığında rastgele olarak

başlatılır. Parçacığın uygunluk değerleri amaç fonksiyonlarına göre hesaplanır. Ziyaret tablosu Eş. (3.52)'de belirtildiği gibi başlatılır.

Adım 2: Hareket stratejisinin seçimi

Parçacıkların güncellenmesinde iki hareket stratejisi önerilmiştir. Belirlenen eşik değerine göre parçacıkların hangi stratejiyi kullanarak hareket edeceği belirlenir.


Algoritma 3.5: Önerilen PS-VTS Yönteminin Sözde Kodu	
Giriş: Populasyon sayısı, maksimum iterasyon sayısı, problem boyutu, w , F_c , FV , altın oran	
Çıkış: Optimal çözüm	
a.	Populasyonu, hızlarını, $pBest$, $gBest$, ϵ değeri, ziyaret tablosu, yön vektörünü başlat,
b.	
c.	
d.	Her parçacığın uygunluk değerini hesapla
e.	$gBest$ ve $pBest$ değerlerini belirle
f.	for $k=1:iter$
a.	for $i=1:Npop$
i.	Yön vektörünü güncelle
ii.	Hedef indeksi güncelle
iii.	if $rand < \epsilon$
1.	$velocity_i$ and $position_i$ Eş. (3.53)'e göre güncelle
iv.	else
1.	$velocity_i$ and $position_i$ Eş. (3.55)'e göre güncelle
v.	endif
vi.	Ziyaret tablosunu güncelle (Eş. 3.52)
vii.	Yeni pozisyonların uygunluk değerlerini ($newF$) hesapla
viii.	if $newF < F_i$
1.	$F_i = newF$
ix.	Endif
b.	Endfor
c.	if $F_i < pBest_i$
i.	$pBest$ & $fitness_pBest$ değerlerini güncelle
d.	endif
e.	$Pbest$ 'in en iyi bireyini new_gBest olarak ata
f.	if $fitness_new_gBest < fgBest$
i.	$gBest$ & $fitness_gBest$ değerlerini güncelle
g.	endif
g.	endfor

Adım 3: Seçilen stratejiye göre güncelleme

Bu bölümde seçilen stratejiye göre parçacıkların konumları ve hızları güncellenmektedir. Yön vektörü, hedef indeks (TI), ziyaret tablosu, yerel ve global optimumlar güncellenir.

Adım 4: Sonlandırma koşullarının kontrol edilmesi

Sonlandırma kriterleri karşılanırsa, optimizasyon sonlandırılacaktır. Aksi takdirde, yineleme sayısı maksimuma ulaşana kadar Adım 2'den devam edilecektir.



Şekil 3.17. Önerilen PS-VTS yönteminin akış şeması

3.3. Duygu Sınıflandırması


Duyguları gerçek hayatta doğru bir şekilde tanımak, insan-bilgisayar etkileşimi (HCI) sistemlerinde çok önemlidir. Elektroensefalogram (EEG) sinyalleri, duyguları tanımlamak için yaygın olarak kullanılmaktadır. Araştırmacılar tarafından önerilen modellerin doğrulanmasında literatürde kullanılan birkaç EEG tabanlı duygu tanımlama veri seti mevcuttur. Literatürdeki çalışmalarda, EEG sinyallerinden sadece kanallar seçilerek çeşitli EEG tabanlı uygulamaların yapıldığı görülmüştür [76], [77], [78], [152]. Bununla birlikte, ritim seçimi EEG sinyal tabanlı uygulamalarda çok önemli bir rol oynamaktadır. EEG sinyallerinin duygu tanıma görevinde en etkin şekilde kullanılabilmesi için bu çalışmada kanal seçimine ek olarak ritim seçimi yapılmıştır. Demir ve ark. [69] tarafından yapılan çalışmada, DEAP veri setini kullanarak kanalları ve ritimleri manuel olarak seçerek EEG ritimlerine dayalı duygu sınıflandırması gerçekleştirilmiştir. Bu çalışmada, yazarlar başlangıçta ayrık dalgacık dönüşümü (DWT) kullanarak her kanal için ritimleri çıkarmışlardır ve her ritim için, özellik çıkarımı için önceden eğitilmiş çeşitli CNN modelleri kullanılmıştır. Çalışmada, duygu kategorizasyonu için bir SVM sınıflandırıcı kullanılmıştır. Yazarlar, belirtilen süreci tüm kanallar için manuel olarak yürütmüşlerdir ancak bu kapsamlı ve zaman alan bir süreçtir. Dolayısıyla, bu çalışmanın motivasyonu, duygu tanıma için meta-sezgisel bir yaklaşımla tüm EEG kanallarından verimli bir ritim ve kanal kombinasyonu seçimi gerçekleştirmektir. Bu nedenle, EEG tabanlı insan duygu tanıma performansını artırmak amacıyla

ziyaret tablosu stratejili parçacık sürüsü (PS-VTS) adı verilen metasezgisel bir yöntem geliştirilmiştir. İlk olarak, EEG sinyallerini gürültüden arındırmak için bir alçak geçiren filtre ve ritim çıkarımı için DWT kullanılmıştır. Özellik çıkarımı için önceden eğitilmiş CNN modeli kullanıldığından, sürekli dalgacık dönüşümü (CWT) yöntemi her ritim sinyalini bir ritim görüntüsüne dönüştürmektedir. [69]'de yazarlar MobilNetv2'nin en iyi doğruluk skorunu ürettiğinden bahsetmişlerdir. Bu nedenle, bu çalışmada da özellik çıkarımı için önceden eğitilmiş MobilNetv2 modelinin kullanılması tercih edilmiştir. Duygu sınıflandırması için DVM sınıflandırıcısı kullanılmıştır. Önerilen metasezgisel yöntem ile optimum kanallar ve ritim kombinasyonu seçilmektedir. Optimizasyon yöntemlerinde girdi ve çıktılar boyutları hesaplama süresini etkilediğinden ve zaman yönetimi uygulamada önemli olduğundan bu aşamada iki model önerilmiştir. DEAP veri seti üzerinde yapılan deneysel çalışmalarda, önerilen yaklaşımın daha az EEG kanalıyla en yüksek duygu sınıflandırma doğruluğunu elde ettiği görülmüştür. Bu çalışmanın katkıları aşağıdaki gibi özetlenebilir:

- ✓ EEG sinyallerinin otomatik kanal ve ritim seçimi sorununu çözmek için Ziyaret Tablolu Parçacık Sürüsü (PS-VTS) Algoritmasına dayalı bir yaklaşım geliştirilmiştir.
- ✓ En etkili kanal ve ritim kombinasyonlarının otomatik seçimi için en uygun çerçeveler aranarak kanal ve ritim kombinasyonlarının seçimi için iki yeni çerçeve sunulmuştur.
- ✓ DEAP veri seti üzerinde yapılan deneyler, önerilen yaklaşımın daha az EEG kanalıyla daha yüksek doğrulukta duygu sınıflandırması gerçekleştirilmiştir

PS-VTS Yaklaşımı ile EEG Sinyallerinden Duygu Sınıflandırması:

EEG beynin elektriksel aktivitesini doğrudan kafa derisine ya da beyne yerleştirilen elektrodlar ile alındığı kayıttır. Beynin elektriksel aktivitesi; koma, uyku/uyanıklık, epilepsi, bazı psikozlar, beyin ölümü gibi uyarılma düzeyindeki değişiklik ile etkilenmektedir. Dalgaların karakteristiği serebral korteksin ilgili bölgelerinin aktivitesine bağlıdır. Koma, epilepsi ve uyku durumunda dalgaların karakteristiği oldukça farklılık göstermektedir. İnsan beyni; frontal, parietal, oksipital, temporal, serebellum lob olmak üzere 5 loba ayrılmaktadır. Frontal lob, bilinçli düşünmede rol oynar. Bu bölgenin zarar görmesi durumunda ruh hali ve hissiyat değişikliği olabilir. Parietal lob, çeşitli duyu organlarından gelen bilgileri birleştirmede önemli rol oynar. Ayrıca nesnelerin kullanılması ve bazı mekansal görüş işlemlerinde parietal lobun kimi bölümleri rol alır. Oksipital lob, görme duyusuyla ilgili bilgilerin işlendiği lobdur. Temporal lob, doku ve sesin algılanması, aynı zamanda da yüzler, mekanlar gibi karmaşık uyaranların işlenmesinde rol oynar. Serebellum, duyu organlarından gelen bilgilerle hareketi ilişkilendirir ve özellikle dengenin sağlanmasında önemli rol oynar. Beyin yapısı ve lobları Şekil 3.18'de görülmektedir.



Şekil 3.18. Beyin yapısı ve lobları

Beyin dalgalarının kafatası yüzeyindeki genlikleri 0-200 mikrovolt ve frekansları 0-30 Hz arasında değişmektedir. EEG sinyalleri alfa, beta, gama, delta ve teta olarak 5 sınıfta incelenmektedir. Bu sinyaller farklı genlik ve özellikteki dalgalar. Ayrıca beyinde oluştukları bölgeler de farklıdır. Bu dalgaların sınıflamaları beynin aktivitesine göre yapılmaktadır. EEG sinyallerinin ritimlerinin oluştukları bölgeler, frekans aralıkları ve sembolleri Tablo 3.3'te sunulmuştur.

Tablo 3.3. EEG sinyallerinin ritimleri ve özellikleri

Bant İsmi	Sembol	Frekans Aralığı	Oluştugu Bölge
Alfa	α	8 Hz-12 Hz	Oksipital Parietal
Beta	β	12 Hz-22 Hz	Frontal
Delta	δ	0.5 Hz-5.5 Hz	Değişken
Gama	γ	22 Hz-30 Hz	Değişken
Teta	θ	4 Hz-7 Hz	Değişken

Alfa dalgaları yaratıcılık ve zihinsel aktivite ile bağlantılıdır. Uyku durumunda ortadan kalkar. Teta dalgası düş kırıklığı ve duygusal durumlarda, beta dalgası; dış dünyaya yönelik olduğu durumlarda, delta dalgası; çok derin uykuda ortaya çıkmaktadır.

Demir ve ark. [69]'nın DEAP veriseti üzerinde yaptıkları çalışmada EEG kanal ve ritim seçimi manuel gerçekleştirilmiştir. Derin özellik çıkarımı ve her kanala ait ritim görüntülerinin çıkarılması başarımlarını yükseltmiş olsa da etkin kanal-ritim seçimi sürecinin manuel yapılması bir eksiklik olarak görülmüştür ve hem otomatik kanal-ritim seçiminin gerçekleştirilmesi hem de duygu sınıflandırma başarımının artırılması amacıyla etkili bir yöntem geliştirilmiştir. Bu çalışmada, Demir ve ark. [69]'nın kullanmış olduğu yöntemler ve bu yöntemlerde kullanılan

parametre değerleri sabit tutulup, başarıyı yüksek ve otomatik bir kanal-ritim seçim modelinin duygu sınıflandırma performansına etkisi incelenmiştir. Bu kapsamda, her kanala ait ritimler çıkarılırken DWT yöntemi kullanılmıştır. Her ritim için 1000 özellik önceden eğitilmiş MobilNetv2 modeli ile çıkarılmıştır. Duygu sınıflandırmasında ise SVM yöntemi kullanılmıştır. Otomatik EEG kanalı ve ritim seçimi için önerilen yöntemle ait akış şeması Şekil 3.19'da gösterilmiştir. İlk adımda EEG sinyalleri ile ilgili veri seti elde edilir. Bu çalışmada kullanılan EEG sinyalleri 32 elektrot ile elde edilmiştir. Duygu tanımlama için kullanılan veri setinin ayrıntıları Bölüm 3.1.6'da verilmiştir. EEG sinyalleri gürültüleri ortadan kaldırmak için başlangıçta düşük geçişli filtreleme ile filtrelenmiştir. EEG sinyallerinin alfa, beta, gama, teta ve delta ritimleri ayrıştırılmıştır. CWT yöntemi kullanılarak sinyallerden görüntülere dönüşüm gerçekleştirilmiştir. Belirtilen DEAP veri seti için 1280 denek, 32 kanal ve beş ritim sinyalinden 32x5x1280 görüntü elde edilmiştir. Derin öznetelik çıkarma adımıyla MobilNetv2 önceden eğitilmiş CNN modeli kullanılarak her görüntüden 1000 öznetelik elde edilmiştir. Her kanal ve ritim görüntüsü ayrı ayrı değerlendirilerek EEG sinyallerinden duygu tanıma performansı incelenmiştir. Doğruluk değerleri belirli bir eşğin altında olan kanal ve ritim görüntüleri elenmiştir. Optimum kanalları ve ritimleri seçmek için PS-VTS yöntemi kullanılmıştır. Optimizasyon sürecinde başlangıçta rastgele seçilen kanal ve ritimlerden elde edilen görüntüler üzerinde derin özellik çıkarımı yapılmıştır. Her görüntüden elde edilen öznetelikler birleştirilerek sınıflandırma performansı artırılmıştır.

Sınıflandırma SVM sınıflandırıcısı ile gerçekleştirilmiştir. Çeşitli örüntü sınıflandırma uygulamalarında SVM algoritması iyi performans gösterdiği için tercih edilmiştir [25]. SVM algoritması, tahmin hatasının en aza indirildiği maksimum marjlı hiperdüzlemi bulmayı amaçlamaktadır. SVM algoritmasının C parametresi [10^{-4} - 10^3] aralığında optimize edilmiştir. Radyal tabanlı çekirdek fonksiyonu (radial basis kernel function) dikkate alınmıştır ve gama parametresi ızgara arama optimizasyon algoritması kullanılarak ayarlanmıştır.

Optimizasyon algoritmasında üretilen her aday çözüm için işlemler gerçekleştirilir. Her iterasyonda uygunluk değerlerine göre en iyi çözümler belirlenir ve saklanır. Ardından, ilgili denklemler kullanılarak yeni aday çözümler güncellenir. Her seferinde, önceki ve yeni uygunluk değerleri karşılaştırılarak optimum değerler güncellenir. İşlem, maksimum iterasyon sayısına ulaşılan kadar tekrarlanır.

PS-VTS Yöntemi ile Kanal ve Ritim Seçimi:

Bu bölümde, optimum EEG kanalı ve ritim seçimi için önerilen Binary PS-VTS yöntemi açıklanmaktadır. PS-VTS optimizasyonu ile EEG kanal seçiminin sözde kodu Algoritma 3.6'da verilmiştir.

Algoritmada EEG görüntüleri, EEG sinyallerini elde etmek için kullanılan elektrot sayısı, popülasyon büyüklüğü ve maksimum iterasyon sayısı giriş verileri olarak verilmektedir. Optimal kanal ve ritim seti ise çıktı olarak elde edilmektedir.

Algorithm 3.6: PS-VTS algoritması ile EEG kanal seçimi	
Giriş:	
• EEG ritim-kanal kümesi: $x(r, k)$ • EEG sinyalinin kanal sayısı • Populasyon boyutu • Maksimum iterasyon sayısı	
Çıkış: Optimum kanal & ritim kümesi	
1.	Popülasyonu, ziyaret tablosunu, yön vektörünü başlat.
2.	Uygunluk değerlerini hesapla.
3.	$gBest$ ve $pBest$ değerlerini belirle
4.	for $r=1:nRthym$
a.	for $k=1:iter$
i.	for $i=1:Npop$
1.	Yön vektörünü güncelle
2.	Hedef indeksi (TI) güncelle
3.	if $rand < 0.5$
a.	Hız ve pozisyonları Eş. (3.53-3.54)'i kullanarak güncelle.
4.	else
a.	Hız ve pozisyonları Eş. (3.55-3.56) kullanarak güncelle.
5.	endif
a.	Ziyaret tablosunu güncelle
b.	$newF$ hesapla
c.	If $newF > F_i$
i.	$F_i = newF$
d.	endif
6.	if $F_i < Pbest_i$
a.	$Pbest_i$ 'i güncelle
7.	endif
ii.	endfor
iii.	$gBest$ 'i güncelle
b.	endfor
c.	ritim- r için optimal kanal kümesini belirle (Schannel)
d.	$gBest$ 'in uygunluk değerlerini
e.	if $Fbest(Number_rhythm) > fgBest$
i.	$fgBest = Fbest(Number_rhythm);$
ii.	$best_rhythm = r;$
iii.	$gBest = Schannel;$
iv.	$NGbest_channel = Nchannel(Number_rhythm);$
f.	endif
5.	endfor

** Schannel: optimal kanal kümesi, Nchannel: optimal kanal kümesi sayısı, NGbest_channel: optimal kanal numaraları, Number_rhythm: ritim sayısı, best_rhythm: optimal ritim.

Başlangıç: İlk adımda, başlangıç popülasyonu, ziyaret tablosu ve yön vektörü başlatılır. Uygulama için ilk olarak (N,Nch) boyutlarında yani (20x20) boyutlarında başlangıç popülasyonu başlatılır. Ardından, popülasyondaki her aday çözüm binary olarak Şekil 3.19'daki gibi başlatılır:

0.0975	0.2784	0.5468	0.95750	0.9648	0.1576	0.9705	0.9571	0.4853	0.8002
0	0	1	1	1	0	1	1	0	1
CH1,	CH2,	CH3, ...						CHn-1,	CHn

Şekil 3.19. Başlangıç popülasyonundan aday bir çözüm kümesinin örneği

Sürekli zamanda oluşturulan parçacık değerlerini ikili değere çevirmek için 0.5'in altındaki parçacıklara 0 ve 0.5 ve üzerindeki parçacıklara "1" değeri atanır. Bu çalışmada "1" ilgili kanalın seçildiğini, "0" ise seçilmediğini göstermektedir. (3.57) - (3.59) eşitlikleri kullanılarak yön vektörü başlatılır [151]:

$$D(k) = 1, k = 1, 2, 3, \dots, dim \quad (3.57)$$

$$D(k) = \begin{cases} 1, & \text{if } k = P(i) \\ 0 & \text{else} \end{cases} \quad (3.58)$$

$$D(k) = \begin{cases} 1, & \text{if } k = randi([1, dim]) \\ 0, & \text{else} \end{cases} \quad k = 1, 2, 3, \dots, n \quad (3.59)$$

Ziyaret tablosu ise Eş. (3.60) kullanılarak başlatılır:

$$VisitTable(i, j) = \begin{cases} Nan & \text{if } i = j \\ 0 & \text{else} \end{cases} \quad (3.60)$$

Uygunluk fonksiyonu ve değerlendirilmesi: EEG kanal seçimi için uygunluk fonksiyonunun sözde kodu Algoritma 3.7'de verilmiştir. Algoritma 3.7'de, Şekil 3.19'daki gibi bir aday çözüm girdi olarak girilir. 0 ve 1 değerlerinden oluşan aday çözüm kümesinde, seçilen kanallar olan 1 değerlerine karşılık gelen kanalların değerleri, schannel adı verilen değişkene atanır. Kanalın boyutu, seçilen kanal sayısını belirler. Seçilen kanal ve ritim sayılarına karşılık gelen EEG sinyallerinin görüntüleri alınır. Veri setindeki her kişi için EEG görüntüleri elde edilir ve kaydedilir. Kaydedilen görüntüler sırayla okunur. MobileNetv2 önceden eğitilmiş CNN modeli ile her kanal için 1280 görüntü okunarak derin öznitelik çıkarımı gerçekleştirilir. Ayıklanan özellikler, Feats1 adlı değişkene atanır. Her görüntüden 1000 özellik çıkarılır. Şekil 3.19'da verilen örnek aday çözüm kümesini kullandığımızı varsayarsak burada 6 kanalın seçildiği görülmektedir. 6 kanallı bir çözüm seti için 1280x6000 boyutlarında bir öznitelik çıkarılır. Çıkarılan çözüm seti, sınıflandırma için SVM'ye girdi olarak verilir. Doğruluk değerleri hesaplanarak bu değerler aday çözüm kümesi ile yapılan duygu tanıma için optimizasyon algoritmasına döndürülür. Popülasyondaki her aday çözüm için uygunluk değeri Algoritma 3.7'den elde edilir. Uygunluk değerlerinden en iyileri seçilerek yerel optimum (p_{best}) ve global optimum (g_{best}) değerleri elde edilir. Ardından, döngü maksimum yinleme sayısı için tekrarlanarak her ritim için en uygun kanal kümesi seçilir. Son olarak, her ritim döngüsünün sonunda, en iyi değer önceki global optimum değer ile karşılaştırılarak optimum kanal ve ritim seti belirlenir.

Algoritma 3.7: PS-VTS ile EEG kanal seçimi için uygunluk fonksiyonunun sözde kodu
Giriş: Aday çözüm kümesi, EEG kanal sayısı
Çıkış: Doğruluk skoru
1. Aday çözüm kümesinden seçilen kanalları $sChannel$ olarak ata.
2. Aday seçilen kanal sayısını N olarak ata.
3. for $j = 1; j < N ; j++$
a. $k = schannel(j)$
b. k^{nci} kanala ait verileri ($data(k)$) yükle
c. for $i=1:1280$
i. i^{nci} örneğe ait $rhythm^{nci}$ görüntüyü ($Image(i, rhythm)$) oku
ii. MobileNetv2 kullanarak görüntünün derin özelliklerini ($Feats1$)'i çıkar
d. endfor
e. $Feats = [Feats, Feats1]$
4. endfor
5. SVM yöntemi ile sınıflandırma
6. Doğruluk skorunu hesapla

**** Feats:** özellik kümesi, **schannel:** seçilen aday kanal kümesi, **N:** seçilen aday kanal sayısı

Güncelleme: Bu adımda, popülasyon iki hız denklemi kullanılarak güncellenir (Eşitlikler 3.53-3.55). Parçacıkların hareket türlerini gerçekleştirme olasılığı %50'dir. Hareket tipi seçildikten sonra, ziyaret tablosundan her parçacık için Hedef İndeks (Target Index - TI) değeri ve yön vektörü hesaplanır. Ardından, parçacıkların hızı ve konumu (3.53-3.56)'da verilen güncelleme denklemleri ile güncellenir. Ziyaret tablosunda, parçacıkların gittiği noktalara '0' atanır ve ziyaret edilmeyen yerlerin değerleri bir artırılarak güncellenir. Daha sonra yeni bulunanların uygunluk değerleri hesaplanır. Bulunan değer mevcut parçacığın bir önceki değerinden daha iyi ise yer değiştirme yapılır; aksi takdirde eski durum korunur. Tüm adayların değerleri güncellendikten sonra pbest ve gbest değerleri en iyi olan aday çözüm kümelerine göre güncellenir. Her ritim için işlemler tekrarlanır. Son olarak, en iyi ritim ve o ritme karşılık gelen optimum kanal global optimum olarak belirlenir.

Ayrık PS-VTS: Önerilen PS-VTS sürekli zaman optimizasyon yöntemi ayrık zamana Eş. (3.61) kullanılarak dönüştürülür:

$$x_i(k+1) = \begin{cases} 1, & TF \geq rand \\ 0, & else \end{cases} \quad (3.61)$$

Burada $rand$ (0, 1) aralığında rastgele bir değerdir. TF , algoritmanın sürekli değerlerini 0 ile 1 arasında ölçeklendiren transfer fonksiyonudur. Bu amaçla TF olarak sigmoid fonksiyonu kullanılır. TF 'nin denklemi aşağıdaki gibidir [153]:

$$TF = \frac{1}{1+e^{v_i(k+1)}} \quad (3.62)$$

4. BULGULAR VE TARTIŞMA

Bu bölümde, görüntü eşikleme ve duygu sınıflandırılması uygulamalarının performansını artırmak için detayları önceki bölümde açıklanan yöntemlerin deneysel bulguları ve bu bulguların ayrıntılı analizleri sunulmuştur. Bu bölümde, her bir yöntemin nasıl uygulandığı ve sonuçlarının ne olduğu gibi detaylı açıklamalar altında incelenmiştir. Bu sayede, her bir yöntemin uygulanabilirliği, etkinliği ve işlevselliği hakkında kapsamlı bir değerlendirme sağlanmıştır. Araştırmanın bu aşamasında, elde edilen sonuçların özgünlüğü ve uygulanabilirliği üzerinde derinlemesine bir analiz yapılarak, ileriye yönelik potansiyel araştırma alanları da belirlenmiştir. Bu bağlamda, sunulan bulgular, görüntü işleme ve duygu sınıflandırma alanında gelecekteki çalışmalara ışık tutacak nitelikte detaylı bir bilgi kaynağı oluşturmuştur.


4.1. GoldSa Yöntemi ile Çok Seviyeli Görüntü Eşikleme

Bu bölüm, geliştirilen 2D-NLM-GoldSa II yöntemine dayalı çok seviyeli eşikleme yönteminin doğruluğunu göstermek amacıyla gerçekleştirilen deneyleri özetlemektedir. Kısaca, eşikleme algoritmasında kullanılan parametrelerin tanımı ve değerleri sunulmuştur. Önerilen yöntem ile görüntüler farklı eşik seviyelerinde bölütlenmiştir ve bölütlenen çıkış görüntülerin başarımları 12 kalite ölçüm indeksi kullanılarak değerlendirilmiştir. Sonuçlar daha sonra mevcut yöntemlerle (ABC, DE, GSA, cKGSA, eKGSA ve PSO) karşılaştırılmıştır. Önerilen yöntemin parametreleri Tablo 4.1’de gösterildiği gibi listelenmiştir, BSDS300 veri setindeki her görüntü 3 seviyeli ve 5 seviyeli eşik değerleri ile bölütlenmiştir. İki boyutlu NLM-GoldSa II’de ajanların aralıkları [1, 255] olarak alınmıştır. Maksimum iterasyon, popülasyon büyüklüğü, eşik seviyesi ve parçacıkların aralıkları tüm yöntemler için eşit alınmıştır. Önerilen yöntemde kullanılan parametreler ve değerleri Tablo 4.1’de sunulmuştur.

Tablo 4.1. Önerilen yöntemin parametreleri

Parametre	Sembol	Değer
Aralık	(ub, lb)	[1, 255]
Eşik seviyesi	d	{3, 5}
Problem boyutu	2*d	{6, 10}
Maksimum iterasyon	t_{max}	1000
Popülasyon boyutu	n	$10 * (d-1) / 2$
Altın oran	τ	0.618033
Rastgele değerler	r_1, r_2, r_3	[0, 1]
Parçacık sayısı	N	100
Arama ajanları	X	
En iyi ajan	x_{best}	
En iyi uygunluk değeri	f_{best}	

BSDS300 veri setinden alınan görüntülerin bir boyutlu ve iki boyutlu histogramları, yerel olmayan araçlar kullanılarak çıkarılmıştır. Veri setinden alınan örnek bir görüntü ve histogramları Şekil 4.1’de sunulmuştur.



Şekil 4.1. 1D ve 2D yerel olmayan ortalamalar histogram örnekleri

Literatürde, görüntü bölümlleme işlemlerinin performansını değerlendirmelerinde çok sayıda kalite ölçüm indeksi kullanılmaktadır. En yaygın kullanılan indeksler BDE, PRI, GCE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD, NAE ve MD'dir [47], [108], [154]. Bu çalışmada, önerilen yöntemin başarısı belirtilen indeksler kullanılarak değerlendirilmiştir. BSDS300 veri setinden alınan 300 görüntü için hesaplanan değerlerin ortalaması alınarak karşılaştırmalı sonuçlar elde edilmiştir. Önerilen iki boyutlu NLM-GoldSa II yöntemi ile görüntülere 3 seviyeli ve 5 seviyeli eşikleme uygulandığında elde edilen ortalama kalite ölçüm indekslerinin değerleri ve diğer metasezgisel yöntemlerle (GSA, ABC, DE, cKGSA, eKGSA ve PSO) karşılaştırmalı olarak Tablolar 4.2-4.7’de sunulmaktadır.

Tablo 4.2.Ortalama BDE & PRI değerleri.

BDE			PRI		
Yöntem	Lv=3	Lv=5	Yöntem	Lv=3	Lv=5
GSA	10.2567	9.9448	GSA	0.6073	0.6610
cKGSA	10.2719	9.8978	cKGSA	0.6070	0.7010
eKGSA	10.2407	9.8776	eKGSA	0.6079	0.7261
PSO	10.0807	9.8568	PSO	0.6144	0.6617
DE	10.4109	10.086	DE	0.5993	0.6450
ABC	10.4560	9.9355	ABC	0.6016	0.6553
GoldSa II	10.0745	9.6869	GoldSa II	0.6172	0.6643

Tablolardaki değerler, BSDS300 veri setinden 300 görüntü için her yöntemin 30 kez çalıştırılmasıyla elde edilen ortalama sonuçları temsil eder. İlk olarak, BDE ve PRI değerleri Tablo 4.2’de verilmiştir. Ardından, BDE ölçüm indeksi, referans görüntü ile bölütlere ayrılmış görüntü arasındaki sınır piksellerinin yer değiştirmesinin ortalama hatasını hesaplar. Daha küçük BDE değerleri, daha iyi segmentasyonu temsil etmektedir. 3-seviyeli ve 5-seviyeli eşiklemede, GoldSa II yöntemi kullanılarak elde edilen BDE değerinin diğer yöntemlerden elde edilen değerler göre daha küçük olduğu Tablo 4.2’de görülmektedir. PRI değeri, iki görüntü arasındaki benzerliği ölçmektedir ve yüksek PRI değeri daha iyi bir bölütleme yapıldığını göstermektedir. BSDS300 veri setinden elde edilen 300 görüntü için ortalama VOI ve GCE değerleri 3-seviyeli ve 5-seviyeli eşikleme için hesaplanmış ve sonuçlar Tablo 4.3’te sunulmuştur.

Tablo 4.3. Ortalama VOI & GCE değerleri.

VOI			GCE		
Yöntem	Lv=3	Lv=5	YÖNTEM	Lv=3	Lv=5
GSA	2.8067	3.1415	GSA	0.3348	0.4396
cKGSA	2.8060	3.1419	cKGSA	0.3345	0.4391
eKGSA	2.8078	3.1436	eKGSA	0.3352	0.4397
PSO	2.8025	3.1479	PSO	0.3381	0.4181
DE	2.7882	3.0676	DE	0.3247	0.4124
ABC	2.7828	3.1283	ABC	0.3238	0.4332
GoldSa II	2.7656	3.0858	GoldSa II	0.3301	0.4279

VOI indeksi, [0, 1] aralığında değerler alarak bölütlenmiş bir görüntüdeki rastgelelik seviyesini hesaplamaktadır. Bir görüntünün hesaplanan VOI değeri ne kadar yüksek olursa, bölütleme performansı o kadar iyi olur. GCE indeksi ise [0,1] aralığında değerlere sahiptir. Bununla birlikte, VOI’den farklı olarak, daha küçük bir GCE değeri, daha iyi bir segmentasyon derecesini göstermektedir. Görüntü bölütleme performansını değerlendirmek için kullanılan diğer indeksler, SSIM ve FSIM değerleridir. Tablo 4.4’te görülebileceği gibi, önerilen yöntem ve diğer altı yöntem kullanılarak ortalama SSIM ve FSIM değerleri hesaplanmıştır.

Tablo 4.4. Ortalama SSIM & FSIM değerleri.

SSIM			FSIM		
Yöntem	Lv=3	Lv=5	Yöntem	Lv=3	Lv=5
GSA	0.4529	0.6566	GSA	0.6749	0.7857
cKGSA	0.4529	0.6569	cKGSA	0.6742	0.7858
eKGSA	0.4549	0.6428	eKGSA	0.6779	0.7812
PSO	0.4705	0.6702	PSO	0.6798	0.7891
DE	0.4423	0.5981	DE	0.6697	0.7549
ABC	0.4398	0.6428	ABC	0.6691	0.6428
GoldSa II	0.4636	0.6715	GoldSa II	0.6809	0.7893

3-seviyeli ve 5-seviyeli bölütlemelerde önerilen yöntem ile elde edilen her iki değer de diğer yöntemlere göre daha düşük olduğu gösterilmiştir, bu da önerilen yöntemle daha iyi bölütleme bir

bölütleme işlemi gerçekleştirildiği anlamına gelmektedir. 3-seviyeli ve 5-seviyeli bölütlemeler için RMSE ve PSNR indekslerinin ortalama değerleri, önerilen yöntem ile birlikte diğer altı bölütleme yöntemi için Tablo 4.5’te verilmektedir.

Tablo 4.5. Ortalama RMSE & PSNR değerleri

RMSE			PSNR		
Yöntem	Lv=3	Lv=5	Yöntem	Lv=3	Lv=5
GSA	50.0514	29.3868	GSA	14.4014	18.9516
cKGSA	50.0259	29.4240	cKGSA	14.4092	18.9810
eKGSA	49.8913	29.3922	eKGSA	14.4306	18.9463
PSO	48.2583	28.9423	PSO	14.6614	19.0708
DE	51.1517	35.1074	DE	14.2079	17.565
ABC	51.7063	30.9452	ABC	14.1617	18.596
GoldSa II	48.2095	28.8793	GoldSa II	14.6251	19.0283

Görüntüleri farklı dinamik aralıklarla karşılaştırmak için, PSNR indeksi kullanılmıştır. PSNR indeksinde daha yüksek bir değer daha iyi bir bölütleme seviyesini göstermektedir. RMSE indeksi ise hatanın standart sapmasıdır ve düşük değerler, daha iyi görüntü bölütleme performansını göstermektedir. 3-seviyeli ve 5-seviyeli bölütlemeler için ortalama CC ve AD değerleri, altı diğer bölütleme yöntemiyle birlikte önerilen yöntem için Tablo 4.6’da sunulmaktadır.

Tablo 4.6. Ortalama CC & AD değerleri


CC			AD		
Yöntem	Lv=3	Lv=5	Yöntem	Lv=3	Lv=5
GSA	0.6517	0.8006	GSA	42.7436	24.9333
cKGSA	0.6517	0.8004	cKGSA	42.7141	24.9601
eKGSA	0.6532	0.8012	eKGSA	42.5637	24.8990
PSO	0.6634	0.8025	PSO	41.3101	24.4807
DE	0.6414	0.7629	DE	43.7985	29.4665
ABC	0.6369	0.7888	ABC	44.2451	26.1351
GoldSa II	0.8831	0.9445	GoldSa II	41.8074	24.8811

AD indeksi, referans görüntü ile bölütleme görüntü arasındaki ortalama hatayı ölçer ve daha düşük bir AD değeri daha iyi bölütlemeyi göstermektedir. Bununla birlikte, CC indeksi için daha yüksek bir değer, daha iyi bir eşikleme performansı düzeyine işaret etmektedir. Tablo 4.6’da görüldüğü gibi eşik sayısı arttıkça CC değeri de artmaktadır. 3-seviyeli ve 5-seviyeli bölütlemeler için MD ve NAE indekslerinin ortalama değerleri, önerilen yöntem ve diğer altı bölütleme yöntemi için Tablo 4.7’de sunulmaktadır. İki görüntü arasındaki normalleştirilmiş mutlak fark ve maksimum hata sırasıyla NAE ve MD olarak hesaplanmaktadır. Daha düşük değerler, her iki ölçüm indeksine göre daha iyi bölütleme performansını göstermektedir.

Tablo 4.7. Ortalama MD & NAE deęerleri

MD			NAE		
Yöntem	Lv=3	Lv=5	Yöntem	Lv=3	Lv=5
GSA	110.9021	69.5218	GSA	0.4100	0.2419
cKGSA	110.9258	69.8932	cKGSA	0.4099	0.2420
eKGSA	110.857	70.1836	eKGSA	0.4080	0.2412
PSO	107.529	70.4983	PSO	0.3965	0.2364
DE	111.1072	79.7659	DE	0.4220	0.2878
ABC	113.7159	73.2606	ABC	0.4257	0.2557
GoldSa II	101.7061	67.2503	GoldSa II	0.4004	0.2396

3-seviyeli ve 5-seviyeli eşiklemeden elde edilen hesaplama süreleri ve uygunluk deęerleri, BSDS300 veri setinden alınan örnek test görüntülerine uygulanmıştır ve sırasıyla Tablo 4.8 ve Tablo 4.9’da sunulmaktadır. Örnek test görüntüleri rasgele seçilmiştir ve Şekil 4.2’de gösterilmektedir. Tablo 4.8 ve Tablo 4.9’daki optimum deęerler koyu renkle vurgulanmıştır. 3-seviyeli ve 5-seviyeli eşiklemeden elde edilen eşik deęerleri karşılaştırmalı olarak Tablo 4.10’da verilmiştir. PSO, eKGSA ve GoldSa II bölütleme yöntemleri için karşılaştırmalı sonuçlar sunulmaktadır.

**Şekil 4.2.** Test Görüntüleri

Tablo 4.10’da optimum deęerler koyu renkle gösterilmiştir. BSDS300 veri setinden alınan bir örnek görüntü için en iyi üç optimizasyon yöntemi kullanılarak elde edilen bölütlenmiş görüntüler karşılaştırmalı olarak Şekil 4.3’te sunulmaktadır.

30 çalıştırmadan sonra her segmentasyon yöntemi için 300 görüntü için ortalama sonuçlar incelenmiştir. 3 seviyeli görüntü eşiklemenin ortalama sonuçlarına göre, geliştirilen tekniğin 12 kalite ölçüm indeksinden yedisinde mevcut diğer yöntemlere göre daha iyi sonuçlar verdiği görülmüştür.

Tablo 4.8. En iyi 3 optimizasyon yöntemleri ile yapılan 3-seviyeli eşikleme için eşik değeri, uygunluk değeri ve hesaplama süresi.

Test Görüntüsü	PSO		eKGSA		GoldSa II	
	Zaman (s)	Uygunluk	Zaman (s)	Uygunluk	Zaman (s)	Uygunluk
Görüntü 1	9.35	24.21	9.23	24.21	9.63	24.21
Görüntü 2	9.01	23.95	9.16	24.01	8.94	22.62
Görüntü 3	10.34	23.12	8.97	23.02	9.88	23.12
Görüntü 4	10.67	22.73	10.99	22.46	10.51	22.73
Görüntü 5	9.14	22.92	11.25	21.75	9.68	23.58
Görüntü 6	8.92	24.24	9.34	24.24	10.21	24.67
Görüntü 7	8.86	24.13	10.0	23.75	8.46	24.13
Görüntü 8	9.49	24.25	9.58	24.25	9.32	24.25


Tablo 4.9. En iyi 3 optimizasyon yöntemleri ile yapılan 5-seviyeli eşikleme için eşik değeri, uygunluk değeri ve hesaplama süresi.

Test Görüntüsü	PSO		eKGSA		GoldSa II	
	Zaman (s)	Uygunluk	Zaman (s)	Uygunluk	Zaman (s)	Uygunluk
Görüntü 1	50.70	36.52	46.72	36.51	46.57	36.52
Görüntü 2	11.98	34.91	12.65	34.88	12.01	36.03
Görüntü 3	14.27	34.26	14.08	33.59	13.89	34.26
Görüntü 4	11.41	37.44	12.60	35.67	12.46	37.51
Görüntü 5	12.36	35.48	14.67	32.45	13.60	35.84
Görüntü 6	12.25	37.48	12.08	37.02	11.83	37.48
Görüntü 7	46.26	36.52	48.94	36.24	48.90	36.54
Görüntü 8	12.28	36.62	12.49	36.62	12.10	36.62

Tablo 4.10. 3-seviyeli ve 5-seviyeli eşiklemede elde edilen optimum eşik değerleri

Test Görüntüsü	nTh	PSO	eKGSA	GoldSa II
Görüntü 1	3	94, 166	93, 166	93, 16
	5	57, 100, 142, 186	58, 101, 145, 191	61, 108, 154, 202
Görüntü 2	3	152, 225	152, 225	171, 23
	5	45, 85, 127, 180	51, 88, 132, 182	93, 148, 193, 221
Görüntü 3	3	27, 135	106, 161	27, 135
	5	28, 60, 98, 139	38, 73, 109, 144	27, 59, 98, 137
Görüntü 4	3	25, 129	85, 135	25, 12
	5	59, 92, 123, 178	59, 120, 176, 225	54, 92, 129, 181
Görüntü 5	3	31, 239	29, 150	32, 22
	5	41, 103, 145, 196	36, 118, 144, 184	63, 102, 140, 198
Görüntü 6	3	112, 179	112, 178	36, 16
	5	36, 111, 159, 206	36, 94, 150, 199	36, 112, 160, 206
Görüntü 7	3	34, 172	116, 177	34, 17
	5	36, 75, 129, 169	46, 80, 135, 177	43, 90, 138, 176
Görüntü 8	3	55, 102, 155, 201	84, 164	84, 16
	5	84, 164	56, 102, 151, 203	50, 93, 144, 200

Bununla beraber, PSO yöntemi dört indekste, ABC yöntemi bir indekste daha iyi sonuç vermiştir. 5 seviyeli görüntü eşiklemesine göre, geliştirilen tekniğin yedi kalite ölçüm indeksinde diğer yöntemlere göre daha iyi sonuç verdiği, PSO, DE ve eKGSA yöntemlerinin ise 12 indeksin ikisinde daha iyi performans gösterdiği görülmüştür. Önerilen yöntem ile BSDS300 veri setinden alınan örnek görüntünün bölütlenmiş görüntüleri Şekil 4.3'te sunulmuştur.



Şekil 4.3. Örnek görüntünün üç farklı yöntemle bölütlenmesi: (a) 3-seviyeli bölütlenme; (b) 5-seviyeli bölütlenme; (c) referans görüntüler

Veri setinden rastgele alınan sekiz görüntü için hesaplama periyotları hem 3-seviyeli eşik hem de 5-seviyeli eşikleme için incelenmiştir (bkz. Tablo 4.8 - Tablo 4.9) ve PSO, eKGSA ve önerilen GoldSa II yöntemleri için de yaklaşık olarak aynı olduğu gösterilmiştir.

4.2. Kaotik Karşıt Öğrenme Tabanlı GoldSa ile Göğüs Kanseri Görüntülerinin Bölütlenmesi

Geliştirilen Kaotik Karşıt Öğrenme Tabanlı Altın Sinüs Algoritması için Deneysel Çalışmalar dört kısımda incelenmiştir. Birinci bölümde deneysel kurulum ele alınmıştır. İkinci bölümde, önerilen kaotik GoldSa yöntemlerinin orijinal GoldSa yöntemiyle karşılaştırıldığında performans analizi, kıyaslama fonksiyonları üzerinde yapılmıştır. Bunun yanı sıra önerilen Co-GoldSa yönteminin standard GoldSa ve cGoldSa ile karşılaştırmalı analizleri yine test fonksiyonları üzerinde yapılmıştır. Üçüncü bölümde, Co-GoldSa yönteminin performans analizi, mühendislik problemleri üzerinde son teknoloji yöntemlerle karşılaştırılarak sunulmuştur. Dördüncü bölümde ise göğüs kanserinin patolojik görüntülerinin bölütlenmesinde Co-GoldSa yöntemine dayalı etkili bir bölütlenme şeması sunulmuştur.

Bu bölümde, önerilen CO-GoldSa'nın performanslarını doğrulamak için bir dizi deney yapılmıştır. Deneyler Intel core-i7 (9. Nesil) işlemci ve 16 GB RAM donanım platformunda Windows 10 ortamında Matlab 2020a kullanılarak gerçekleştirilmiştir.

Bu çalışmanın kıyaslama fonksiyonları yaygın olarak kullanılan klasik fonksiyonlardan seçilmiştir [10], [155]. GoldSa yöntemlerini test etmek için 6 kıyaslama fonksiyonu kullanılmıştır. Seçilen kıyaslama fonksiyonları dört çok modlu fonksiyon ve iki tek modlu fonksiyondan

oluşmaktadır. Tek modlu fonksiyonların tek bir çözümü varken, çok modlu fonksiyonların birçok optimum çözümü vardır. Tek modlu fonksiyonlar, önerilen algoritmanın yakınsama yeteneğini gösterebilir. Multimodal fonksiyonlarda en iyi çözümlerden biri global en iyi çözüm, diğerleri ise yerel en iyi çözümdür. f_1 , f_2 ve f_6 fonksiyonları ayrılmaz, diğerleri ayrılabilir fonksiyonlardır. Algoritmanın yerel optimuma takılmadan global optimuma ulaşması iyi bir algoritma olduğunu göstermektedir. Bu, algoritmaların keşif yeteneği hakkında bilgi vermektedir. Kullanılan 6 kıyaslama fonksiyonunun ayrıntıları Tablo 4.11’de verilmiştir.

Tablo 4.11. GoldSa yönteminin uygulamasında kullanılan test fonksiyonları

No	Fonksiyon ismi	Formül	$f_{\min}$	Tür	Aralık
F ₁	Griewank	$f(X) = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	0	Çok modlu, Ayrılmaz	[-600, 600]
F ₂	Ackley	$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i)\right) + 20 + e$	0	Çok modlu, Ayrılmaz	[-35,35]
F ₃	Rastrigin	$f(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i)] + 10$	0	Çok modlu, Ayrılabilir	[-5.12,5.12]
F ₄	Sphere	$f(x) = \sum_{i=1}^n (x_i)^2$	0	Çok modlu, Ayrılabilir	[-100,100]
F ₅	Quartic	$f(x) = \sum_{i=1}^D i x_i^4$	0	Tek modlu, Ayrılabilir	[-1.28,1.28]
F ₆	Rosenbrock	$f(x) = \sum_{i=1}^{D-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$	0	Tek modlu, Ayrılmaz	[-30,30]

Test Fonksiyonları Üzerinde Deneysel Çalışmalar ve Sonuçlar:

Bu kısımda, cGoldSa yöntemlerinin performans analizleri gerçekleştirilmiştir. cGoldSa1, cGoldSa2 ve cGoldSa3 yöntemlerinden elde edilen istatistiksel sonuçlar Tablo 4.12 – Tablo 4.14’te sunulmaktadır. Sonuçların ortalaması otuz bağımsız çalışma ile gerçekleştirilmiştir. Tablolarda “orijinal”, standard GoldSa ile gerçekleştirilen değerleri ifade etmektedir. Daha sonra sırasıyla Logistic, Sinusoidal, Sine, Gauss, Chebyshev, Circle, Singer ve Tent kaotik haritaları ile elde edilen değerler verilmiştir. GoldSa yöntemi için rastgele parametrelerin kaotik davranışları Tablo 4.12 ve Tablo 4.13’de incelenmiştir. Goldsa II yönteminde doğrusal olarak azalan fonksiyon olarak tanımlanan drt fonksiyonunun kaotik davranışı Tablo 4.14’de incelenmiştir. Tablo 4.12 – Tablo 4.14’de, orijinal GoldSa’dan daha iyi olan sonuçlar koyu renkle vurgulanmıştır. cGoldSa1 ile elde edilen istatistiksel sonuçlar Tablo 4.12’de verilmiştir. Sonuçlar altı kıyaslama fonksiyonu ile ortalama, en iyi, en kötü ve standart sapmalar açısından incelenmiştir. Tablo 4.12’de

görüldüğü gibi lojistik, chebysev ve circle kaotik haritaları ortalama, en iyi, en kötü ve standart sapma değerleri açısından neredeyse tüm kıyaslama fonksiyonlarında standart GoldSa'dan daha iyi performans göstermektedir. Şarkıcı ve Gauss kaotik haritaları ise diğer yöntemlere göre daha kötü sonuçlar göstermektedir. Ayrıca circle haritası beş kıyaslama fonksiyonunda (F1, F2, F4-F6) en başarılı kaotik harita olarak bulunmuştur. Lojistik haritası ise sadece Rastrigin (F3) fonksiyonunda en iyi sonuca sahip kaotik harita olarak bulunmuştur.

Tablo 4.12. cGoldSa1 yönteminden elde edilen istatistiksel sonuçlar

F1	Ort.	Min.	Maks.	Std.	F2	Ort.	Min.	Maks.	Std.
Orjinal	3.70e-2	0	1.70e-1	4.96e-2	Orjinal	5.54e-12	2.22e-14	4.81e-11	1.17e-11
Logistic	9.60e-3	0	1.09e-1	2.99e-2	Logistic	1.74e-12	1.50e-14	1.09e-11	2.90e-12
Sinusoidal	1.00e-3	0	8.33e-2	1.49e-2	Sinusoidal	3.04e-12	2.22e-14	4.41e-11	9.94e-11
Sine	8.80e-3	0	5.91e-2	1.86e-2	Sine	1.23e-12	1.86e-14	5.47e-12	1.77e-12
Gauss	2.20e-3	0	4.52e-1	1.01e-2	Gauss	5.90e-12	3.28e-14	9.04e-11	2.00e-11
Chebysev	2.20e-3	0	2.87e-2	7.20e-3	Chebysev	1.55e-12	7.99e-15	1.55e-11	3.55e-12
Circle	9.72e-4	0	1.87e-2	4.10e-3	Circle	4.08e-15	8.88e-16	7.99e-15	1.58e-15
Singer	5.10e-3	0	1.02e-1	2.28e-2	Singer	6.83e-12	2.22e-14	9.97e-11	2.20e-11
Tent	1.63e-2	0	6.77e-2	2.52e-2	Tent	9.66e-12	1.15e-14	1.66e-10	3.71e-11
F3	Ort.	Min.	Maks.	Std.	F4	Ort.	Min.	Maks.	Std.
Orjinal	5.78e-1	2.24e-46	4.0281	7.56e-1	Orjinal	2.45e-23	8.40e-28	1.31e-22	4.10e-23
Logistic	1.58e-3	0	3.16e-2	7.08e-3	Logistic	1.89e-23	5.74e-30	3.37e-21	7.51e-23
Sinusoidal	4.66e-1	0	7.9694	1.6918	Sinusoidal	2.06e-23	1.23e-28	2.65e-22	8.96e-23
Sine	3.34e-1	0	6.6828	1.4941	Sine	9.32e-24	8.08e-29	8.84e-23	2.58e-23
Gauss	1.89e-1	0	3.7853	8.46e-1	Gauss	1.54e-22	4.83e-30	2.17e-21	5.08e-22
Chebysev	2.84e-1	0	3.7364	7.22e-1	Chebysev	6.76e-24	1.82e-28	1.25e-22	2.79e-23
Circle	7.58e-2	0	1.5145	3.38e-1	Circle	2.64e-32	1.55e-51	4.91e-31	1.09e-31
Singer	3.28e-1	0	4.9271	1.1426	Singer	6.98e-23	3.66e-31	6.73e-23	1.72e-23
Tent	4.20e-1	0	5.8571	1.4003	Tent	5.78e-22	1.42e-29	5.48e-21	1.47e-21
F5	Ort.	Min.	Maks.	Std.	F6	Ort.	Min.	Maks.	Std.
Orjinal	2.51e-3	7.25e-5	9.57e-4	2.58e-4	Orjinal	1.7680	2.16e-2	2.2053	4.54e-1
Logistic	2.25e-4	2.95e-5	8.53e-4	2.57e-4	Logistic	1.4840	1.97e-3	1.9590	4.42e-1
Sinusoidal	3.02e-4	1.90e-5	8.95e-4	2.42e-4	Sinusoidal	1.4670	6.62e-3	2.0266	3.35e-1
Sine	2.95e-4	7.88e-6	7.79e-4	2.37e-4	Sine	1.7160	1.1942	1.9764	3.42e-1
Gauss	3.71e-4	6.71e-5	1.13e-3	2.67e-4	Gauss	1.4505	3.38e-2	2.0359	3.07e-1
Chebysev	2.37e-4	3.01e-5	7.17e-4	1.94e-4	Chebysev	1.4691	1.66e-2	1.9037	3.40e-1
Circle	1.38e-4	1.95e-5	3.14e-5	2.00e-4	Circle	1.2132	1.49e-2	1.9046	1.73e-1
Singer	3.39e-4	9.98e-5	9.93e-4	2.74e-4	Singer	1.6429	2.81e-2	2.0512	4.79e-1
Tent	2.99e-4	3.49e-5	8.17e-4	2.35e-4	Tent	1.6809	1.1250	1.9899	2.80e-1

Tablo 4.13, cGoldSa2'ye ilişkin istatistiksel sonuçları temsil etmektedir. cGoldSa2 yönteminin geliştirilmesinde chebysev, circle, sinüs ve tent haritalarının başarılı olduğu görülmektedir. Bununla birlikte, Gauss ve Singer haritalarının diğer yöntemlere nazaran daha başarısız olduğu görülmüştür. Ayrıca circle kaotik haritası cGoldSa2 yönteminde beş test fonksiyonu (F1-F5) için en başarılı harita olarak bulunmuştur. Sine haritası yalnızca Rosenbrock fonksiyonu (F6) için en başarılı sonuca sahip kaotik harita olarak bulunmuştur.

Tablo 4.14'ten elde edilen sonuçların çoğunda lojistik, sinüs, Chebysev ve circle kaotik haritalarının cGoldSa3 yönteminin performansını iyileştirmede başarılı olduğu, Gauss, Singer ve Tent haritalarının ise başarısız olduğu görülmektedir. Ayrıca F2, F3 ve F4 test fonksiyonları için sinüs kaotik haritası cGoldSa2 yaklaşımındaki en başarılı haritadır. F1, F5 ve F6 fonksiyonlarında ise circle kaotik haritaya dayalı olarak geliştirilen yöntem daha başarılıdır.

Tablo 4.13. cGoldSa2 yönteminden elde edilen istatistiksel sonuçlar

F1	Ort.	Min.	Maks.	Std.	F2	Ort.	Min.	Maks.	Std.
Orjinal	3.70e-2	0	1.70e-1	4.96e-2	Orjinal	5.54e-12	2.22e-14	4.81e-11	1.17e-11
Logistic	5.01e-3	0	1.66e-1	4.34e-2	Logistic	1.90e-12	7.99e-15	1.00e-11	3.15e-12
Sinusoidal	1.33e-3	0	7.71e-2	2.57e-2	Sinusoidal	6.04e-12	1.39e-13	1.91e-11	5.95e-12
Sine	1.06e-1	2.22e-16	3.07e-1	7.36e-2	Sine	2.18e-12	4.44e-15	1.85e-11	4.50e-12
Gauss	8.46e-2	21.09e-2	1.82e-1	4.56e-2	Gauss	1.29e-11	1.50e-13	1.28e-10	2.81e-11
Chebysev	1.98e-2	0	5.72e-2	1.87e-2	Chebysev	2.11e-12	7.99e-15	1.25e-11	3.77e-12
Circle	5.76e-6	0	1.10e-2	2.57e-05	Circle	3.37e-15	8.88e-16	4.44e-15	1.67e-15
Singer	1.86e-1	5.70e-12	4.27e-1	1.35e-1	Singer	1.80e-12	7.99e-15	1.89e-11	4.21e-12
Tent	9.47e-4	0	1.89e-2	4.23e-3	Tent	4.31e-13	7.99e-15	2.29e-12	5.79e-13
F3	Ort.	Min.	Maks.	Std.	F4	Ort.	Min.	Maks.	Std.
Orjinal	5.78e-1	2.24e-46	4.0281	7.56e-1	Orjinal	2.45e-23	8.40e-28	1.31e-22	4.10e-23
Logistic	4.08e-1	0	5.5839	1.2815	Logistic	5.96e-23	1.15e-30	9.32e-22	2.13e-22
Sinusoidal	3.32e-1	0	2.8939	7.56e-1	Sinusoidal	4.17e-21	1.27e-26	4.31e-20	1.07e-20
Sine	4.73e-1	0	3.6906	1.2448	Sine	4.70e-24	4.80e-29	4.67e-23	1.06e-23
Gauss	6.52e-1	0	5.8709	8.91e-1	Gauss	1.93e-22	2.04e-27	2.13e-21	5.54e-22
Chebysev	6.01e-2	0	1.2093	2.70e-1	Chebysev	1.30e-23	7.36e-28	1.29e-22	3.55e-22
Circle	3.80e-3	0	7.60e-3	1.70e-3	Circle	4.91e-34	5.52e-48	9.74e-33	2.17e-33
Singer	6.18e-1	0	7.0924	1.7787	Singer	4.22e-22	3.01e-29	6.33e-21	1.44e-21
Tent	5.49e-1	0	1.0888	2.43e-1	Tent	6.78e-23	3.43e-28	9.71e-22	2.19e-22
F5	Ort.	Min.	Maks.	Std.	F6	Ort.	Min.	Maks.	Std.
Orjinal	2.51e-3	7.25e-5	9.57e-4	2.58e-4	Orjinal	1.7680	2.16e-2	2.2053	4.54e-1
Logistic	3.98e-4	4.94e-5	1.12e-3	2.73e-4	Logistic	1.5150	4.28e-1	2.0572	4.73e-1
Sinusoidal	2.58e-4	1.89e-5	5.85e-4	1.56e-4	Sinusoidal	1.5910	1.03e-1	1.9337	3.98e-1
Sine	4.06e-4	5.83e-5	8.92e-4	2.37e-4	Sine	1.2078	1.14e-2	1.9083	4.50e-1
Gauss	7.93e-4	1.43e-4	1.76e-3	4.98e-4	Gauss	1.5199	7.31e-2	2.1381	5.27e-1
Chebysev	2.68e-4	2.15e-5	6.51e-4	2.03e-4	Chebysev	1.4748	1.91e-2	1.9119	3.49e-1
Circle	3.67e-5	1.65e-05	1.00e-4	2.91e-5	Circle	1.4675	9.04e-2	1.7679	1.87e-1
Singer	9.11e-4	3.01e-4	2.19e-3	5.56e-4	Singer	1.8402	1.45e-1	1.9292	1.27e-1
Tent	2.89e-4	3.31e-6	7.95e-4	2.17e-4	Tent	1.5150	4.28e-1	1.9572	3.73e-1

Tablo 4.14. cGoldSa3 yönteminden elde edilen istatistiksel sonuçlar

F1	Ort.	Min.	Maks.	Std.	F2	Ort.	Min.	Maks.	Std.
Orjinal	3.70e-2	0	1.70e-1	4.96e-2	Orjinal	5.54e-12	2.22e-14	4.81e-11	1.17e-11
Logistic	4.79e-3	0	4.93e-2	1.47e-2	Logistic	3.05e-14	4.44e-15	2.46e-13	5.79e-14
Sinusoidal	1.21e-2	0	3.29e-2	1.34e-2	Sinusoidal	1.81e-12	1.92e-14	2.53e-11	5.59e-12
Sine	3.08e-3	0	6.15e-2	1.37e-2	Sine	6.75e-15	8.88e-16	2.57e-14	5.67e-15
Gauss	4.23e-2	2.74e-09	6.27e-2	2.61e-2	Gauss	2.70e-08	5.43e-12	2.51e-07	5.62e-08
Chebysev	6.23e-3	0	4.81e-2	1.54e-2	Chebysev	1.30e-13	4.44e-15	8.60e-13	2.32e-13
Circle	2.13e-3	0	2.26e-2	9.54e-3	Circle	9.03e-13	1.77e-14	4.97e-12	1.28e-12
Singer	6.51e-2	7.25e-4	1.56e-1	4.41e-2	Singer	3.63e-06	1.69e-11	3.70e-05	9.08e-06
Tent	3.70e-2	0	2.77e-1	8.53e-2	Tent	1.31e-06	9.69e-11	1.31e-05	3.34e-06
F3	Ort.	Min.	Maks.	Std.	F4	Ort.	Min.	Maks.	Std.
Orjinal	5.78e-1	2.24e-46	4.0281	7.56e-1	Orjinal	2.45e-23	8.40e-28	1.31e-22	4.10e-23
Logistic	8.84e-8	0	1.76e-06	3.95e-7	Logistic	2.51e-25	5.45e-33	4.85e-24	1.08e-24
Sinusoidal	5.00e-1	0	5.7279	1.5197	Sinusoidal	5.64e-21	1.37e-28	1.09e-19	2.45e-20
Sine	6.39e-15	0	1.13e-13	2.54e-14	Sine	1.79e-30	1.16e-37	2.13e-29	5.07e-30
Gauss	1.2997	0	4.7390	1.6528	Gauss	1.23e-14	5.62e-22	1.44e-13	3.30e-14
Chebysev	2.62e-2	0	4.0242	9.44e-2	Chebysev	1.00e-24	1.24e-31	1.16e-23	3.11e-24
Circle	1.01e-4	0	2.03e-3	4.55e-4	Circle	2.45e-23	9.60e-29	1.16e-22	3.90e-23
Singer	4.0932	1.70e-09	9.6943	3.7037	Singer	8.48e-11	7.32e-17	1.49e-09	3.32e-10
Tent	4.3494	0	20.5299	7.006	Tent	3.35e-09	1.31e-19	6.68e-08	1.49e-08
F5	Ort.	Min.	Maks.	Std.	F6	Ort.	Min.	Maks.	Std.
Orjinal	2.51e-3	7.25e-5	9.57e-4	2.58e-4	Orjinal	1.7680	2.16e-2	2.2053	4.54e-1
Logistic	3.49e-4	6.58e-5	9.10e-4	2.43e-4	Logistic	1.5390	2.00e-2	1.8717	4.23e-1
Sinusoidal	2.54e-4	5.39e-5	7.67e-4	2.15e-4	Sinusoidal	1.2257	5.60e-3	1.8543	6.52e-1
Sine	2.69e-4	5.56e-5	7.27e-4	1.66e-4	Sine	1.5055	1.0338	1.7334	1.86e-1
Gauss	8.34e-4	4.60e-5	2.00e-3	4.97e-4	Gauss	1.7689	5.80e-2	1.8958	6.42e-1
Chebysev	2.87e-4	1.95e-5	7.58e-4	2.02e-4	Chebysev	1.4190	2.02e-2	1.9045	4.31e-1
Circle	2.48e-4	3.15e-5	6.34e-4	1.75e-4	Circle	6.12e-1	1.52e-3	1.2576	3.83e-2
Singer	7.28e-4	4.94e-5	3.96e-3	5.76e-4	Singer	1.4652	2.13e-2	1.9536	5.73e-1
Tent	5.96e-4	2.03e-4	1.27e-3	3.28e-4	Tent	1.8456	1.03e-1	2.7134	6.68e-1

Sonuç olarak Tablo 4.12 ve Tablo 4.13'e göre GoldSa-II yöntemini geliştirmek için kullanılan rastgele parametreler üzerinde sinüs, circle ve chebysev kaotik haritalarının etkili olduğu sonucuna varılabilir. Lineer olarak azalan bir fonksiyon yerine kaotik haritaların kullanılması durumunda, lojistik, sinüs, chebysev ve daire kaotik haritalarının başarılı olduğu görülmektedir (Tablo 4.14). Öte yandan Gauss ve Singer haritaları neredeyse tüm yöntemlerde başarılı bir iyileşme göstermediği görülmüştür.

Tablo 4.15. Co-GoldSa, GoldSa ve cGoldSa yöntemlerinin istatistiksel sonuçları

	Griewank fonksiyonu				Ackley fonksiyonu			
	Ort.	Min.	Maks.	Std.	Ort.	Min.	Maks.	Std.
Orjinal	3.70e-2	0	1.70e-1	4.96e-2	5.54e-12	2.22e-14	4.81e-11	1.17e-11
CGoldSa2	1.33e-3	0	7.71e-2	2.57e-2	3.37e-15	8.88e-16	4.44e-15	1.73e-15
CO-GoldSa	0	0	0	0	2.66e-15	8.88e-16	4.44e-15	1.67e-15
	Rastrigin fonksiyonu				Sphere fonksiyonu			
	Ort.	Min.	Maks.	Std.	Ort.	Min.	Maks.	Std.
Orjinal	5.78e-01	2.24e-46	4.0281	7.56e-01	2.45e-23	8.40e-28	1.31e-22	4.10e-23
CGoldSa2	3.80e-04	0	7.60e-03	1.70e-03	4.91e-34	5.52e-48	9.74e-33	2.17e-33
Co-GoldSa	3.72e-10	0	7.45e-09	1.66e-09	1.91e-41	5.02e-52	2.26e-40	5.43e-41
	Quartic fonksiyonu				Rosenbrock fonksiyonu			
	Ort.	Min.	Maks.	Std.	Ort.	Min.	Maks.	Std.
Orjinal	2.51e-3	7.25e-5	9.57e-4	2.58e-4	1.8745	1.5732	2.1845	2.64e-01
CGoldSa2	2.48e-4	3.15e-5	6.34e-4	1.75e-4	1.4675	9.04e-01	1.7679	1.87e-01
Co-GoldSa	2.34e-4	5.51e-5	6.31e-4	1.36e-4	1.2465	2.89e-04	1.4908	5.91e-02

Bununla birlikte, ortalama değerler açısından en iyi sonuçlar Griewank fonksiyonunda circle kaotik haritası ile geliştirilen cGoldSa2 yönteminde, Ackley fonksiyonunda daire kaotik haritası ile geliştirilen cGoldSa2 yönteminde, Rastrigin fonksiyonunda sinüs haritası ile geliştirilen cGoldSa3 yönteminde, Sphere fonksiyonunda circle haritası ile geliştirilen cGoldSa2 yönteminde, Quartic fonksiyonunda circle kaotik haritası ile geliştirilen cGoldSa2 yönteminde ve Rosenbrock fonksiyonu üzerinde circle haritası ile geliştirilen cGoldSa3 yönteminde elde edilmiştir. Tablo 4.12 - Tablo 4.14'ten elde edilen sonuçlara göre circle kaotik haritasıyla geliştirilmiş cGoldSa2 yöntemi en iyi kaotik GoldSa yöntemi olarak belirlenmiştir.

Karşıtlık temelli öğrenme stratejisi, yöntemin kesinliğini ve yakınsama hızını arttırmak amacıyla circle kaotik harita ile zenginleştirilmiş olan cGoldSa2 yöntemine entegre edilerek Co-GoldSa yöntemi geliştirilmiştir. Orijinal GoldSa, cGoldSa2 ve Co-GoldSa'nın istatistiksel sonuçları Tablo 4.15'de gösterilmektedir. Tablo 4.15'te görülebileceği gibi cGoldSa'nın standart GoldSa'ya kıyasla daha kesin çözümler elde ederek bu yöntemin performansının üzerine çıktığı görülmüştür. Bununla birlikte, Co-GoldSa algoritması orijinal GoldSa ve cGoldSa ile karşılaştırıldığında daha kesin çözümler elde ettiği anlaşılmaktadır.

Mühendislik Problemleri Üzerinde Deneysel Çalışmalar ve Sonuçlar:

Önerilen yöntem, dört klasik mühendislik tasarım problemi üzerinde test edilip diğer metasezgisel yöntemlerle karşılaştırmalı olarak değerlendirilmiştir. Karşılaştırılan metasezgisel yöntemler MVO, MFO, WOA, Aritmetik Optimizasyon Algoritması (Arithmetic Optimization Algorithm-AOA), Kaya Kartalı Optimizasyonu (Aquila Optimizer-AO), Çita Optimizasyonu (Cheetah Optimizer-CO), Sürüngen Arama Algoritması (Reptile Search Algorithm-RSA), Geometrik Ortalama Optimizasyonu (Geometric Mean Optimizer-GDO) ve Kar Küreme Optimizasyonu (Snow Ablation Optimizer-SAO)'dur. Kullanılan mühendislik tasarım problemleri çekme/basma yayı tasarımı ve kaynaklı kiriş tasarımı, basınçlı boru tasarımı ve üç çubuklu kafes tasarım problemleridir. Bu dört mühendislik problemi üzerinde yapılan deneylerde başlangıç popülasyon büyüklüğü 20, maksimum iterasyon sayısı ise 1000 olarak belirlenmiştir. Problemlerin detayları Bölüm 3.1.2'de detaylı olarak açıklanmıştır.

Çekme/basma yayı tasarım probleminde; Bölüm 3.1.2'de verilen eşitliklerde de görüleceği üzere dört kısıt vardır. Bobin sayısı, bobin çapı ve tel çapı değişkenleri, geliştirilmiş GoldSa ve diğer meta-sezgisel yöntemler kullanılarak optimize edilmiştir.

Tablo 4.16. Çekme/basma yay tasarım problemi için karşılaştırmalı sonuçlar.

Çekme/Basma Yay Tasarımı				
Metot	Ort.	Min.	Maks.	Std.
MVO (2015)	1.698e-2	1.291e-2	1.812e-2	1.646e-3
MFO (2015)	1.342e-2	1.267e-2	1.777e-2	1.250e-3
WOA (2016)	1.399e-2	1.267e-2	1.777e-2	1.441e-3
AOA (2021)	1.427e-2	1.298e-2	3.097e-2	4.213e-3
AO (2021)	1.646e-2	1.326e-2	2.388e-2	2.215e-3
CO (2022)	1.553e-2	1.281e-2	1.903e-2	1.694e-3
RSA (2022)	1.455e-2	1.293e-2	3.683e-2	5.323e-3
GMO (2023)	1.297e-2	1.267e-2	1.395e-2	3.077e-4
SAO (2023)	1.321e-2	1.266e-2	1.694e-2	7.351e-4
Co-GoldSa	1.268e-2	1.267e-2	1.271e-2	9.072e-5

Önerilen yönteme ait istatistiksel sonuçlar, Tablo 4.16'da diğer dokuz yöntemle karşılaştırmalı olarak verilmiştir. Tablo 4.16'da önerilen Co-GoldSa yönteminin ortalama, minimum, maksimum ve standart sapma sonuçları bakımından diğer yöntemlerden üstün olduğu görülmüştür. Bu sonuçlar Co-GoldSa'nın rakiplerine kıyasla en optimum değişkenleri minimum ağırlıkla sağlayabildiğini göstermektedir.

Kaynaklı kiriş tasarım probleminde; çubuk kalınlığı (b), kaynağın kalınlığı (h), çubuk yüksekliği (t) ve bağlanan parçanın uzunluğu optimize edilmiştir. Bu değişkenler iki doğrusal ve beş doğrusal olmayan eşitsizlik koşullarıyla sınırlandırılmıştır. Önerilen yönteme ait istatistiksel sonuçlar, Tablo 4.17'de verilmiştir. Tablo 4.17'de verilen deneysel sonuçlar, önerilen yöntemin kirişin optimum tasarım değişkenini bulmada daha iyi performansa sahip olduğunu göstermektedir.

Tablo 4.17. Kaynaklı kiriş tasarım problemi için karşılaştırmalı sonuçlar.

Kaynaklı kiriş tasarım problemi				
Metot	Ort.	Min.	Maks.	Std.
MVO (2015)	1.7425	1.7265	1.8815	2.332e-1
MFO (2015)	1.7718	1.7248	2.2686	1.022e-1
WOA (2016)	2.3042	1.7721	5.0729	6.226e-1
AOA (2021)	2.3028	1.8707	3.0640	2.856e-1
AO (2021)	1.9607	1.7762	2.3861	1.316e-1
CO (2022)	2.2236	1.7664	3.1043	3.544e-1
RSA (2022)	2.1499	1.8418	2.5806	1.772e-1
GMO (2023)	1.8907	1.7491	2.0041	5.678e-2
SAO (2023)	1.7397	1.7248	2.0006	5.362e-3
Co-GoldSa	1.7276	1.7248	1.7323	1.645e-3

Basınçlı boru tasarım probleminde; Bölüm 3.1.2’de verilen eşitliklerde de görüleceği üzere dört kısıt vardır. Bu problemde, minimum maliyetini elde etmek amaçlanmaktadır. Kafa kalınlığı (Th), kabuk kalınlığı (Ts), silindirik bölümün kafa uzunluğu (L) ve iç yarıçap (R) olmak üzere dört değişken optimize edilmektedir. Önerilen yönteme ait istatistiksel sonuçlar, Tablo 4.18’de verilmiştir. Önerilen yöntemin ortalama, en iyi, en kötü ve standart sapma sonuçları açısından üstünlüğü tablodan görülmektedir. Bunun yanısıra, MFO ve SAO yöntemleri, Co-GoldSa’dan sonra diğer yöntemlere kıyasla daha iyi sonuçlar vermektedir.

Tablo 4.18. Basınçlı boru tasarım problemi için karşılaştırmalı sonuçlar.

Basınçlı boru tasarım problemi				
Yöntem	Ort.	Min.	Maks.	Std.
MVO (2015)	6.823e+3	5.910e+3	7.564e+3	4.645e+3
MFO (2015)	6.306e+3	5.885e+3	7.319e+3	5.612e+3
WOA (2016)	8.172e+3	6.262e+3	1.648e+4	2.013e+3
AOA (2021)	3.671e+4	7.425e+3	1.956e+5	4.053e+4
AO (2021)	6.826e+3	6.037e+3	7.701e+3	5.065e+2
CO (2022)	7.414e+3	6.415e+3	9.511e+3	6.586e+3
RSA (2022)	1.007e+4	7.520e+3	1.180e+4	4.550e+3
GMO (2023)	6.383e+3	6.140e+3	7.068e+3	1.716e+2
SAO (2023)	6.526e+3	5.885e+3	7.318e+3	5.452e+2
Co-GoldSa	3.059e+3	2.832e+3	3.525e+3	1.170e+2

Üç çubuklu kafes tasarım probleminde; kirişin ağırlığını yapısal tasarım değişkeniyle en aza indirmek amaçlanmaktadır. Bölüm 3.1.2’de verilen eşitliklerde de görüleceği üzere probleme ait üç kısıt vardır. Önerilen yönteme ait istatistiksel sonuçlar, Tablo 4.19’da verilmiştir. Elde edilen deneysel bulgular, Co-GoldSa’nın bu tür zorlukları çözmedeki etkililiğini göstermektedir. Önerilen yöntemin; ortalama, minimum, maksimum ve standart sapma istatistiksel özellikleri açısından tüm mühendislik problemlerinin uygulanmasında diğer metasezgisel yöntemlerden daha üstün performans gösterdiği bulunmuştur. Ayrıca MFO, GDO ve SAO yöntemlerinin diğer yöntemlerden daha iyi performansa sahip olduğu görülmüştür.

Tablo 4.19. Üç çubuklu kafes tasarım problemi için karşılaştırmalı sonuçlar.

Üç çubuklu kafes tasarım problemi				
Metot	Ort.	Min.	Maks.	Std.
MVO (2015)	263.8990	263.8980	263.9014	1.05e-3
MFO (2015)	263.9211	263.8958	264.1535	4.81e-2
WOA (2016)	264.2469	263.8960	266.4126	5.52e-1
AOA (2021)	264.7704	263.9708	266.0298	5.86e-1
AO (2021)	265.3121	263.9642	270.7181	1.5999
CO (2022)	264.1792	263.9003	266.5225	4.34e-1
RSA (2022)	265.1371	263.9108	269.7372	1.1759
GMO (2023)	263.8994	263.8958	263.9146	4.58e-3
SAO (2023)	263.9126	263.8958	264.1887	4.81e-2
Co-GoldSa	263.8965	263.8958	263.9005	9.33e-4

Co-GoldSa ve literatürde mühendislik problemleri için sunulan diğer metasezgisel yöntemler ile elde edilen sonuçların karşılaştırması Tablo 4.20’de sunulmuştur.

Tablo 4.20. Önerilen yöntemin mevcut yöntemlerle klasik mühendislik problemleri için karşılaştırmalı sonuçları.


METOT	Çekme/Basma Yay Tasarım problemi	Kaynaklı kiriş tasarım problemi	Basıncılı boru tasarım problemi	Üç çubuklu kafes tasarım problemi
CoGoldSa	1.267e-02	1.7248	2.832e+03	263.8958
EHOI [156]	1.266e-02	1.7265	-	-
BBO [157]	-	1.8077	6.592e+03	-
BPSO [157]	-	1.7328	7.198e+03	-
SSA [158]	1.267e-02	1.7249	-	263.8958
CPSO [159]	1.267e-02	1.7280	6.061e+03	-
GWO [124]	1.267e-02	1.7262	-	-

Tabloda sunulan sonuçlar incelendiğinde önerilen yöntemin çekme/basma yay tasarımı probleminde 1.7248 optimum ağırlıkla en iyi performansa sahip olduğu görülmüştür. Karşılaştırılan yöntemlerden yalnızca SSA [158] ve EHOI [156] yöntemleri sırasıyla 1.7249 ve 1.7265 ile Co-GoldSa yöntemine yakın sonuçlar elde etmiştir. Basıncılı kap tasarım probleminde ise önerilen yöntemin 2.832e+03 optimum değeri ile en iyi sonuca sahip olduğu görülmektedir. Bu problemde, verilen yöntemlerden sadece CPSO [159] yöntemi 6.061e+03 optimum değeri ile önerilen yöntemle yakın bir değerdedir. Öte yandan, çekme/basma yayı tasarımı problemi ve üç çubuk kafes tasarım probleminde önerilen yöntem diğer yöntemlerle benzer sonuçlar üretmiştir.

Göğüs Kanserinin Patolojik Görüntüleri Üzerinde Deneysel Çalışmalar ve Sonuçlar:

Bu bölümde, önerilen Co-GoldSa yöntemi çok seviyeli eşikleme görüntü bölütleme (Multilevel Thresholding Image Segmentation-MTIS) problemine uygulanmıştır. Yöntem MVO, MFO, WOA, AOA, AO, CO, RSA ve SAO olmak üzere diğer meta-sezgisel yöntemle karşılaştırılmıştır. MTIS deneyleri, Göğüs Invaziv Duktal Karsinoma (Breast Invasive Ductal Carcinomas-BIDC) veri seti kullanılarak gerçekleştirilmiştir. Önerilen yöntemin üstünlüğünü daha iyi ortaya koymak için veri


setinden en detaylı ve karmaşık altı görüntü seçilmiştir. Seçilen test görüntüleri Şekil 4.4'de gösterilmektedir.



Şekil 4.4. Invaziv Duktal Karsinoma göğüs patoloji görüntüleri.

Ayrıca daha fazla doğrulama için MTIS deneyleri düşük eşik seviyelerinde (4, 6 ve 8) ve yüksek eşik seviyelerinde (12, 16 ve 18) gerçekleştirilmiştir. Deney sonuçları SSIM, FSIM ve PSNR indeksi gibi görüntü kalitesi ölçüm indeksleri kullanılarak değerlendirilmiştir.

Meme kanseri görüntülerinin histogramları, yerel olmayan ortalamalar (Non-Local Means-NLM) histogram yöntemi ile oluşturulmuştur. Seçilen test görüntüleri ve bunların 1D&2D histogramları Şekil 4.5’de gösterilmektedir ve önerilen MTIS yöntemine ait akış şeması Şekil 4.6’da sunulmaktadır. Şekil 4.6’da görülebileceği gibi, giriş görüntüleri gri seviyeli görüntülere dönüştürülür. Dönüştürülen görüntüler, 2 boyutlu bir histogram oluşturmak için NLM yöntemine gönderilir. Önerilen Co-GoldSa yöntemi ile görüntü için en uygun eşikleme değerleri bulunmaktadır. Optimizasyon algoritmasının maliyet fonksiyonu olarak Renyi'nin eşikleme yöntemi kullanılmıştır. Elde edilen eşik değerleri ile görüntü ilgili bölgelere bölünerek segmente edilir. Segmente edilen görüntülerin kalitesi SSIM, FSIM ve PSNR gibi görüntü kalitesi ölçüm indeksleri ile değerlendirilir.




Şekil 4.5. Test görüntüleri ve 1D&2D histogramları.

Tablo 4.21. Elde edilen 2D Renyi'nin optimum entropi deęerleri.

Test Görüntüsü 1						
	4	6	8	12	16	20
MVO (2015)	23.9928	30.4826	34.8458	44.6224	52.0319	58.1354
MFO (2015)	24.2929	29.9852	35.8126	44.2460	51.7092	57.9543
WOA (2016)	24.2929	30.2683	35.6603	44.5967	52.0556	58.4888
AOA (2021)	25.2082	31.4041	37.0466	47.1151	54.9046	62.8693
AO (2021)	24.9043	31.0136	36.5584	46.8703	55.5031	51.6142
CO (2022)	24.8084	31.0136	36.3585	46.4031	55.8892	63.1070
RSA (2022)	24.9043	30.9368	36.3308	46.2454	54.5398	62.0843
SAO (2023)	24.9048	31.0136	36.5587	46.8759	55.8911	63.5992
Co-GoldSa	25.2407	31.5474	37.0704	47.1601	55.3929	63.8624
Test Görüntüsü 2						
MVO (2015)	24.3152	30.0841	35.7507	44.0281	51.2944	57.8245
MFO (2015)	24.2510	30.0838	35.2924	44.0542	50.8800	57.5974
WOA (2016)	24.3152	30.0756	35.2708	44.0722	51.5546	57.9533
AOA (2021)	24.6444	30.9871	36.5744	47.0161	55.7755	63.5731
AO (2021)	24.3004	30.5278	36.0998	46.4231	55.5014	54.2649
CO (2022)	24.3004	30.5278	36.0998	46.5266	55.3570	63.6016
RSA (2022)	24.2978	30.5003	36.0255	45.9849	54.2599	62.1746
SAO (2023)	24.3004	30.5278	36.0998	45.8664	55.3847	63.7687
Co-GoldSa	24.6506	31.1160	37.0534	47.0973	56.1098	64.5794
Test Görüntüsü 3						
MVO (2015)	23.6637	30.0774	35.2233	44.1023	51.8111	57.9257
MFO (2015)	23.3711	29.2794	35.0615	43.4670	51.1056	56.8755
WOA (2016)	23.6637	29.5654	35.1174	44.0386	51.3903	58.2347
AOA (2021)	24.8107	31.2467	37.0731	47.6277	56.6072	65.6380
AO (2021)	24.6671	31.0012	37.2286	48.3396	57.9831	50.7084
CO (2022)	24.6671	31.0012	37.2286	48.3225	58.0907	66.5597
RSA (2022)	24.6666	30.9945	37.1472	48.0166	57.4457	65.9203
SAO (2023)	24.6671	31.0012	37.2286	48.3448	57.0955	66.7947
Co-GoldSa	24.8203	31.3321	37.3292	47.9319	58.1635	64.8903
Test Görüntüsü 4						
MVO (2015)	22.7331	28.0429	33.9476	43.0982	50.7393	56.7493
MFO (2015)	22.7263	27.7853	33.8465	40.8002	49.9145	56.7971
WOA (2016)	22.7331	27.4456	33.7011	43.1881	50.8106	57.3787
AOA (2021)	23.4391	29.2699	34.7419	44.4032	51.7850	60.5190
AO (2021)	23.3321	29.0992	34.2432	43.5671	54.0653	47.7407
CO (2022)	23.3321	29.0992	34.2342	43.5764	51.7198	62.2710
RSA (2022)	23.3270	29.0623	34.1601	42.9780	53.0502	60.8406
SAO (2023)	23.3321	29.0992	34.2342	43.5730	52.9003	62.4074
Co-GoldSa	23.4472	29.3548	34.9227	43.9508	52.5700	59.5439
Test Görüntüsü 5						
MVO (2015)	23.0463	29.0113	34.0130	42.9609	50.6216	56.9629
MFO (2015)	21.9186	28.9316	34.0122	43.0091	50.3366	56.4648
WOA (2016)	23.0463	29.0098	34.2034	43.0549	50.6349	57.1093
AOA (2021)	24.4325	30.7715	36.4400	46.7595	55.0930	63.1573
AO (2021)	24.0563	30.4554	36.2189	46.1920	54.9310	58.6452
CO (2022)	24.0563	30.4554	36.2179	46.2047	54.9791	62.4683
RSA (2022)	24.0563	30.4536	36.0759	45.7493	53.6665	60.9741
SAO (2023)	24.0563	30.4554	36.2178	46.2004	54.9725	63.1148
Co-GoldSa	24.4496	30.9624	36.8160	47.1482	55.1834	63.2513
Test Görüntüsü 6						
MVO (2015)	23.3777	28.6724	34.0401	43.9070	51.1323	57.7854
MFO (2015)	22.9634	28.2550	33.9623	42.5707	49.8101	57.5364
WOA (2016)	23.2759	28.8732	34.0238	43.8082	50.2882	57.4154
AOA (2021)	24.3147	30.6873	36.8365	46.6489	55.5048	64.2473
AO (2021)	24.1894	30.5917	36.6765	47.5490	57.4144	46.7378
CO (2022)	24.1894	30.5078	36.6642	47.7483	56.9964	66.4165
RSA (2022)	24.1868	30.5758	36.6605	47.1993	56.1566	63.5917
SAO (2023)	24.1894	30.5917	36.6765	47.5487	57.7651	66.4554
Co-GoldSa	24.3951	30.8003	36.6765	47.0033	55.9924	64.1125


Seilen altı test görüntüsü, önerilen yöntem ve dięer dokuz meta-sezgisel yöntemle 4, 6, 8, 12, 16 ve 20 eşik seviyelerinde bölütlenmiştir. Adil bir karşılaştırma için tüm algoritmalar eşit

şartlarda ve aynı bölütleme çerçevesi ile gerçekleştirilmiştir. Maksimum yinleme, çalıştırma sayısı ve popülasyon boyutu tüm algoritmalar için sırasıyla 1000, 10 ve 20 olarak ayarlanmıştır. Optimum eşik değerleri için Renyi'nin entropisinin elde edilen değerleri, Tablo 4.21'de verilmiştir. Tablo 4.21'de koyu renkle vurgulanan değerler en iyi değerleri temsil etmektedir



Şekil 4.6. Önerilen MTIS yönteminin akış şeması.

Optimum eşik değerleri, Renyi'nin Entropisinin maksimum olduğu noktada bulunur. Tablo 4.21'e göre en yüksek entropiye sahip noktalar Co-GoldSa yöntemiyle elde edilmektedir. Ayrıca AO, CO ve SAO yöntemleri ile de bazı görüntüler için çeşitli eşik seviyelerinde maksimum entropi noktalarına ulaştığı gözlenmektedir.



Şekil 4.7. Önerilen yöntem ile bölütlenmiş görüntüler

SSIM, FSIM ve PSNR endekslerinin deneysel sonuçları Ek 8-10'da gösterilmektedir. Belirtilen Tablolardaki veriler incelendiğinde hemen hemen tüm görüntüler için en iyi değerler önerilen Co-GoldSa yöntemiyle elde edilmiştir. Bununla birlikte, SAO yöntemi 3., 5. ve 6. test görüntüleri için 12 ve 20'inci eşik seviyelerinde rekabetçi sonuçlara sahip olduğu gözlenmiştir. Ek olarak, AO ve CO yöntemleri ile bazı görüntülerin çeşitli düzeylerinde önerilen yöntem ile aynı SSIM, FSIM ve PSNR değerleri elde edilmiştir. Verilen tüm görüntülerin ortalama SSIM, FSIM ve PSNR değerleri Tablo 4.22 – Tablo 4.24'de sunulmuştur.

Tablo 4.22. Tüm görüntülerin ortalama SSIM değeri.


	4	6	8	12	16	20
MVO (2015)	0.2210	0.1893	0.4152	0.3892	0.4561	0.5466
MFO (2015)	0.2491	0.4006	0.4218	0.4006	0.3602	0.4261
WOA (2016)	0.2715	0.2268	0.3744	0.4073	0.4803	0.4480
AOA (2021)	0.5745	0.6563	0.7531	0.8415	0.8577	0.8757
AO (2021)	0.6161	0.6161	0.7927	0.8697	0.8983	0.8996
CO (2022)	0.5551	0.7143	0.7699	0.8493	0.8711	0.8918
RSA (2022)	0.6184	0.7190	0.7727	0.8568	0.8829	0.9041
SAO (2023)	0.6220	0.7307	0.7540	0.8676	0.9010	0.9087
Co-GoldSa	0.6425	0.7420	0.8140	0.8140	0.9012	0.9150

Tablo 4.23. Tüm görüntülerin ortalama FSIM değeri.

	4	6	8	12	16	20
MVO (2015)	0,3709	0,3332	0,5439	0,5227	0,5567	0,6077
MFO (2015)	0,3825	0,5124	0,5512	0,5465	0,4904	0,5485
WOA (2016)	0,4051	0,3925	0,5105	0,5462	0,5808	0,5642
AOA (2021)	0,6397	0,7504	0,8233	0,8813	0,8885	0,9183
AO (2021)	0,6993	0,7913	0,8421	0,9062	0,9304	0,9314
CO (2022)	0,6801	0,7872	0,8398	0,8946	0,9107	0,9255
RSA (2022)	0,6973	0,8016	0,8267	0,9022	0,9168	0,9351
SAO (2023)	0,7008	0,7913	0,8379	0,9014	0,9341	0,9421
Co-GoldSa	0,7242	0,7940	0,8625	0,9179	0,9368	0,9445

Tablo 4.24. Tüm görüntülerin ortalama PSNR değeri.

	4	6	8	12	16	20
MVO (2015)	9.0915	8.7682	12.1288	12.1260	13.141	14.321
MFO (2015)	9.1771	10.980	12.2257	12.6412	11.805	12.967
WOA (2016)	9.4267	9.6102	11.4454	12.4724	13.423	13.244
AOA (2021)	12.013	13.470	16.3773	19.4986	21.125	21.820
AO (2021)	13.017	15.702	17.5330	20.6275	0.8983	22.740
CO (2022)	11.375	15.071	16.6651	16.6651	21.364	22.514
RSA (2022)	13.044	15.931	17.2296	20.2414	21.591	23.058
SAO (2023)	13.013	15.702	17.2418	20.6443	22.543	23.485
Co-GoldSa	13.827	16.123	18.1175	20.9633	22.747	23.638




Şekil 4.8. Test görüntüsü 3 ve 4 için bölütlenen gri ölçekli ve renklendirilmiş görüntüler

Tablo 4.25. Tüm yöntemler için elde edilen hesaplama süreleri

Test Görüntüsü 1						
	4	6	8	12	16	20
MVO (2015)	22.0800	8.0974	6.4331	7.6635	6.7422	6.2189
MFO (2015)	32.4701	9.2976	7.4175	5.8528	6.0900	5.5500
WOA (2016)	19.2651	10.0974	8.6158	8.7184	10.2849	9.2220
AOA (2021)	30.1715	23.2252	21.9025	27.6234	17.9280	16.2602
AO (2021)	65.6200	63.4571	59.7817	49.9413	51.8600	63.9557
CO (2022)	10.1659	8.2975	8.3611	5.1263	3.3018	3.9752
RSA (2022)	43.1568	40.3571	43.9911	46.2698	34.2006	31.6671
SAO (2023)	39.4629	24.7309	19.7751	24.5078	25.9790	16.6891
Co-GoldSa	10.6334	8.4302	7.1155	5.0525	3.8821	3.4014
Test Görüntüsü 2						
MVO (2015)	25.5111	11.7164	7.4698	5.9769	6.8441	5.1379
MFO (2015)	29.4341	9.9571	7.5262	6.2629	5.7483	4.7153
WOA (2016)	16.0140	11.4236	9.1186	10.9258	10.4126	10.2388
AOA (2021)	26.2770	24.8904	21.4614	43.3775	19.2577	18.3257
AO (2021)	75.4321	62.8442	58.0567	49.8975	49.9298	63.6457
CO (2022)	11.6189	10.5514	9.9367	10.1125	10.2393	9.9772
RSA (2022)	47.8963	39.2806	43.4417	42.6993	35.2192	33.6758
SAO (2023)	42.2778	23.3772	18.8306	22.8698	24.2574	16.7651
Co-GoldSa	11.3586	8.4487	7.0127	6.1778	4.9268	4.4276
Test Görüntüsü 3						
MVO (2015)	26.3677	8.1126	7.3277	7.4624	5.5473	4.6287
MFO (2015)	35.3100	6.4821	8.4070	6.5089	5.2593	3.8037
WOA (2016)	17.4480	9.6806	9.2255	10.4149	9.3799	7.9665
AOA (2021)	26.7803	22.4411	21.0495	26.7930	18.0370	17.6126
AO (2021)	70.0105	84.3141	63.9273	50.3760	47.8176	66.2404
CO (2022)	11.5930	10.6297	10.3031	10.1501	9.9679	4.4262
RSA (2022)	50.9778	39.4283	41.7529	34.1849	35.5742	33.5498
SAO (2023)	38.0050	20.9948	21.4041	23.0688	24.3704	16.7632
Co-GoldSa	10.7809	8.5287	7.1285	5.5191	4.8272	4.3150
Test Görüntüsü 4						
MVO (2015)	27.9822	9.8760	5.0203	7.0817	5.1981	4.7149
MFO (2015)	28.5053	10.3583	6.0430	7.8903	4.3388	4.2410
WOA (2016)	16.4540	11.8836	8.3595	10.4795	9.7156	6.5139
AOA (2021)	26.8773	41.0468	21.8202	20.3911	17.8903	16.3274
AO (2021)	72.9972	78.0944	70.4009	52.0009	56.9280	62.3143
CO (2022)	11.5812	10.4944	8.3976	6.2876	4.0333	5.8619
RSA (2022)	43.0540	48.4733	45.1414	43.5324	30.4412	37.3746
SAO (2023)	40.9023	26.4209	20.9983	29.0489	26.6924	18.0059
Co-GoldSa	10.6612	8.5113	7.1421	5.5966	4.9323	4.3472
Test Görüntüsü 5						
MVO (2015)	29.9190	10.4065	5.4605	7.4257	5.7546	5.3416
MFO (2015)	30.8099	9.1070	7.5190	5.0948	4.9156	5.4657
WOA (2016)	14.0755	12.6601	9.9276	10.7108	9.2754	6.9313
AOA (2021)	27.7669	60.6440	20.8340	23.4074	18.2856	16.0077
AO (2021)	82.6701	81.4469	64.2831	53.9589	45.5132	62.4583
CO (2022)	11.0903	9.5326	6.6782	5.0832	4.0075	5.3196
RSA (2022)	49.8222	49.5996	37.8397	50.8143	29.8594	34.1560
SAO (2023)	45.2813	23.5083	20.5832	32.4070	24.2035	18.1934
Co-GoldSa	10.9565	8.5289	7.2079	5.4320	4.8650	4.2853
Test Görüntüsü 6						
MVO (2015)	31.7014	10.3801	5.1652	8.0566	4.8215	5.2258
MFO (2015)	28.7503	8.9579	6.3158	4.8137	4.8884	5.2192
WOA (2016)	14.2897	10.5810	10.0333	8.7641	8.1485	6.1945
AOA (2021)	29.6780	35.1363	23.2618	20.1223	17.2723	16.9330
AO (2021)	72.6898	76.0275	59.2799	51.5503	48.3769	65.4650
CO (2022)	11.9423	8.6874	8.7918	4.3535	5.0337	5.2342
RSA (2022)	53.1430	49.5994	38.9299	38.3046	30.0003	32.4572
SAO (2023)	39.9248	23.0431	19.4882	27.8897	24.7439	17.4131
Co-GoldSa	10.9879	8.4553	7.0999	5.5583	5.0385	4.6025

Bu tablolarda görüldüğü gibi Co-GoldSa yönteminin tüm eşik düzeylerinde diğer sekiz meta-sezgisel yöntemlere kıyasla daha üstün sonuçlar elde ettiği bulunmuştur. Tablo 4.22'den görüleceği üzere önerilen yöntemle elde edilen ortalama değerler hemen hemen kıyılanan tüm algoritmalarından elde edilen ortalama değerlerden daha iyi olsa da yeni algoritmalarından biri olan SAO algoritması ile on ikinci eşik düzeyinde elde edilen ortalama SSIM sonucu en iyi sonuç olarak bulunmuştur. Tablo 4.23'e bakıldığında altıncı eşik düzeyinde yine yeni algoritmalarından biri olan RSA yöntemiyle en iyi ortalama FSIM sonucu bulunmuştur. Önerilen yöntemle yirminci eşik seviyesinde bölütlenmiş gri-ölçekli ve color-map-jet ile renklendirilmiş görüntüler Şekil 4.7'de sunulmaktadır. Ayrıca Şekil 4.8'de 3 ve 4 numaralı test görüntülerinin önerilen yöntemle ve diğer sekiz meta-sezgisel algoritma ile bölütlenmiş görüntüleri karşılaştırmalı olarak sunulmaktadır. Önerilen yöntem ve diğer meta-sezgisel algoritmalar ile Renyi entropisinin yirminci eşik seviyesinde elde edilen değerlerinin yakınsama eğrileri Şekil 4.9'da verilmiştir. Verilen bu şekilde önerilen yöntemin optimum noktayı diğer yöntemlere kıyasla daha kısa sürede yakınsadığı görülmüştür. Ayrıca, başlangıç popülasyonunun oluşturulmasında kullanılan karşıtlık temelli öğrenme stratejisi sayesinde diğer algoritmalarla göre daha doğru bir noktadan başladığı da Şekil 4.9'da görülmektedir. Tüm algoritmaların 4, 6, 8, 12, 16 ve 20 eşik seviyelerinde optimum çözümü elde etme süreleri Tablo 4.25'te altı görüntü için karşılaştırmalı olarak verilmiştir. Sonuçların çoğunda önerilen yöntem, optimum çözümü daha kısa sürede yakınsamıştır. Bununla birlikte, CO ve MVO algoritmalarında bazı görüntüler için eşik düzeylerinin birkaçında önerilen yöntem ile rekabetçi sonuçlar ürettiği ve kısa sürede optimum çözüme yaklaştığı da görülmektedir.




Şekil 4.9. Tüm yöntemler için Renyi'nin entropisinin yakınsama eğrileri

4.3. Kaotik Olarak Zenginleştirilmiş Rao Algoritması ile Adaptif Çok Seviyeli Görüntü Eşikleme


Bu bölüm, görüntü bölütleme yöntemiyle ilgili yapılan deneyi özetlemektedir. Önerilen algoritmanın optimum eşik değerlerini belirlemedeki etkinliğini vurgulamak için farklı histogramlara sahip veri setindeki 300 test görüntüsü kullanılarak deneyler yapılmıştır. Önerilen adaptif CER algoritmasına dayalı bölütleme, 2.4 GHz ve Intel(R) çift çekirdekli işlemcili ve Microsoft Windows 10 sistemi ile 2 GB belleğe sahip bir bilgisayarda MATLAB'da simülasyonlarla doğrulanmıştır. Öncelikle farklı seviyelerde yapay görüntüler oluşturulmuştur ve bu görüntülerin optimum eşik seviyeleri önerilen yaklaşım ile elde edilerek doğrulanmıştır. Daha sonra farklı histogramlara sahip 300 gerçek görüntü için adaptif CER algoritması ile adaptif eşik seviyeleri ve değerleri elde edilerek bu görüntüler bölütlenmiştir. Yöntemin etkililiği, literatürde yaygın kullanılan 12 görüntü kalitesi ölçüm indeksi kullanılarak gerçekleştirilmiştir. Önerilen yöntem kullanılarak elde edilen değerler; DE, ABC, GSA, KGSA, cKGSA gibi metasezgisel yöntemlere dayanan hali hazırda bildirilen çok seviyeli eşikleme algoritmalarıyla karşılaştırılır. Yaklaşımın performansı verisetindeki referans görüntüler kullanılarak değerlendirilir. Önerilen yöntemin etkinliğini göstermek için Berkeley-Benchmark bölütleme veri seti (Berkeley-Benchmark Segmentation Dataset-BSDS) kullanılmıştır. Önerilen CER algoritması ile eşikleme seviyesi uyarlamalı olarak belirlenir. BSDS300 veri kümesindeki örnek görüntüler 320x240 olarak yeniden boyutlandırılır. BSDS300 veri setinden alınan bazı örnek görüntüler ve bunların histogramları (1D ve 2D histogramlar) önerilen bölütleme yöntemiyle elde edilen eşik değerleri ile birlikte Şekil 4.10'da gösterilmektedir.

Önerilen yöntemin doğruluğunu göstermek için yöntem öncelikle yapay olarak oluşturulan görüntülere uygulanmıştır. Şekil 4.11'de bölütleme numarası beş olan olarak oluşturulan yapay gri görüntü ve histogramları verilmiştir. Verilen görüntüye önerilen uyarlamalı çok seviyeli eşikleme yöntemi uygulandığında elde edilen optimum değerler, Şekil 4.11(b)'deki 1d histogramda gösterilmiştir. 1-25 arası seviyeler için önerilen çok seviyeli eşikleme yöntemi verilen yapay gri görüntüye uygulanmıştır ve elde edilen uygunluk değerleri Şekil 4.12'de sunulmuştur.




Şekil 4.10. Orijinal görüntüler ve histogramları.

** 2D histogramda, x eksen ve y eksen pixel değerlerine karşılık gelir ve z eksen, her bir yoğunluk seviyesinin frekansına karşılık gelir. 1d-histogram ve 2D-histogramda, pixel değerleri aralığı 0-255 arasındadır.




Şekil 4.11. Yapay görüntü ve histogramları (a) orijinal görüntü, (b) 1d-histogram (c) 2D-histogram

Seviye sayısı arttıkça uygunluk değerinin 5. seviyeye gelene kadar sürekli arttığı ve bu değerden sonra sabit kaldığı sonucuna varılmıştır. Uygunluk değerlerinin hata grafiği de Şekil 4.12(b)'de verilmiştir.



Şekil 4.12. 5-seviyeli olarak oluşturulan yapay görüntüye ait (a) Uygunluk değerleri, (b) Hata grafikleri

Ayrıca önerilen yöntem Şekil 4.13'te verilen 3-seviyeli ve 4-seviyeli olarak oluşturulan yapay görüntülere uygulanmıştır. Şekilde CER algoritması ile elde edilen eşik değerleri 1d histogramlar ile birlikte görselleştirilmiştir.




Şekil 4.13. Oluşturulan 3-seviyeli ve 4-seviyeli yapay görüntüler ve 1d histogramları

Önerilen yöntemin performansını gerçek görüntüler üzerinde incelemek için yöntem BSDS300 veri setindeki görüntülere uygulanmıştır. Elde edilen uygunluk değerleri histogramlarla birlikte Şekil 4.14'te gösterilmiştir. Şekil 4.14 incelendiğinde yapay görüntülerde olduğu gibi gerçek görüntülerde de uygunluk değerinin gerçek bölüt sayısına kadar arttığı görülmektedir. Bölüt sayısı daha da artırıldığında uygunluk değerinin sabit kaldığı veya bazı noktalarda bir miktar azaldığı şekilde açıkça görülmektedir.

Önerilen çok seviyeli eşikleme yöntemi, Rao algoritmasına uygulanan 8 kaotik haritanın performanslarını karşılaştırmak için BSDS300 veri setindeki 300 görüntüye uygulanmıştır. Her yöntemde, Otsu'nun yöntemine dayalı adaptif eşik seviyesini bulan bölütleme yöntemi uygulanmıştır. Görüntü histogramları GLCM tarafından oluşturulmuştur. Daha güvenilir bir değerlendirme için BDE, PRI, GCE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD, NAE ve MD gibi iyi bilinen görüntü bölütleme performans ölçütleri kullanılmıştır.

BDE, bölütlere ayrılmış görüntüler arasındaki sınır piksellerinin yer değiştirmesinin ortalama hatasını hesaplar. Diğer görüntü sınırındaki piksel ile en yakın piksel arasındaki mesafe olarak tanımlanır. Daha iyi bir bölütleme için daha düşük bir BDE değeri tercih edilir.



Şekil 4.14. (a) Orijinal görüntüler (b) Uygunluk değeri grafiği, (c) CPU zaman grafiği

GCE indeksi (0-1) aralığındadır. Değer ne kadar düşük olursa, bölütleme o kadar iyi olduğu anlamına gelir. VOI, iki bölütleme arasındaki mesafeyi ortalama koşullu entropi cinsinden tanımlayarak bölütlenmiş bir görüntüdeki rastgelelik miktarını hesaplar. PRI, bir görüntüdeki iki bölge arasındaki benzerliklerin bir göstergesidir. Bu indeks 0 ile 1 arasında değişmektedir. Daha iyi bölütleme için PRI yüksek olmalıdır. SSIM, orijinal görüntü ile bölütlenmiş görüntü arasındaki benzerlikleri ölçen bir göstergedir. Daha yüksek SSIM değeri, daha iyi performans anlamına gelir. Özellik benzerlik indeksinde (FSIM), orijinal görüntü ile bölütlenmiş görüntü arasındaki benzerlikleri değerlendiren bir dizindir. PSNR, farklı dinamik aralıklara sahip görüntüleri karşılaştırmak için kullanılır. Daha yüksek bir PSNR değeri, daha iyi bir eşikleme performansını gösterir. Eşik sayısı arttıkça CC değeri artar. Daha yüksek bir CC değeri, daha iyi bir eşikleme performansını gösterir. AD, referans görüntü ile bölütlenmiş görüntü arasındaki farkın ortalamasıdır. Daha iyi bölütleme için düşük AD değeri tercih edilir. MD, iki görüntü arasındaki maksimum hatayı alır. Daha küçük bir MD değeri, daha iyi bölütleme yapıldığı anlamına gelir. NAE, iki görüntü arasındaki normalleştirilmiş mutlak farkı hesaplar. İyi bir bölütleme için düşük NAE değeri tercih edilir.

Optimum eşik seviyeleri bölütlenen 300 görüntü için bulunmuş olup, Tablo 4.26'daki değerler adaptif eşik değerlerine göre bölütlenmiş 300 görüntünün ortalama değerlerini göstermektedir. Tabloda en iyi sonuçlar koyu renkle vurgulanmıştır. Tablo 4.26'da sunulan değerler hem kaotik haritaların üstünlüğünü hem de önerilen uyarlamalı yöntemin performansını göstermeyi amaçlamaktadır. Her bir yöntem için maksimum iterasyon sayısı 1000 olarak alınmıştır. Popülasyon büyüklüğü 20 olarak alınmıştır. Diğer parametreler, Tablo 3.2'de verilmiştir. 300 test görüntüsünün ortalama BDE, PRI, VOI, GCE, SSIM, FSIM, RMSE, PSNR, NK, AD, CC, MD ve NAE değerleri dikkate alınarak yapılan istatistiksel analizden, optimum eşik değerlerinin elde edilmesinde önerilen kaos tabanlı Rao algoritmalarının daha iyi olduğu görülmüştür. Ayrıca Chebyshev Haritasının diğer yedi kaotik harita arasında optimum eşik değerleri elde etmede birinci sırada yer aldığı tespit edilmiştir.

Tablo 4.26. Önerilen Rao algoritmaları ve 8 kaotik haritanın karşılaştırılması

	Orjinal Rao	Rao - Logistic	Rao - Sine	Rao - Sinusoidal	Rao - Gauss	Rao - Circle	Rao - Chebyshev	Rao - Singer	Rao - Tent
BDE	10.6399	10.6961	10.6768	10.6611	10.6366	10.5747	10.7019	10.4845	10.6666
PRI	0.6571	0.6573	0.6553	0.6582	0.6563	0.6525	0.6572	0.6504	0.6573
VOI	3.2278	3.2325	3.2184	3.2397	3.1709	3.0750	3.2499	3.0694	3.2176
GCE	0.4489	0.4491	0.4451	0.4507	0.4438	0.4305	0.4523	0.4262	0.4479
SSIM	0.5754	0.5759	0.5730	0.5771	0.5674	0.5520	0.5776	0.5468	0.5719
FSIM	0.7195	0.7194	0.7175	0.7201	0.7156	0.7073	0.7206	0.7076	0.7171
RMSE	37.2159	37.1993	37.3643	37.1183	37.8773	38.9668	37.0342	39.3624	37.5154
PSNR	17.1129	17.1202	17.0719	17.1459	16.9411	16.6611	17.1568	16.5686	17.0284
AD	28.9327	28.9031	29.0916	28.8071	29.8157	31.2260	28.6930	31.6779	29.1868
CC	1.6665	1.6643	1.6721	1.6635	1.6941	1.7422	1.6563	1.7559	1.6758
MD	113.330	113.170	113.740	113.3500	114.460	115.050	113.4300	115.5900	114.0400
NAE	0.2774	0.2767	0.2789	0.2757	0.2857	0.2997	0.2748	0.3045	0.2798

Önerilen adaptif bölütleme yöntemleri ile 5 örnek görüntü için elde edilen optimum eşik seviyeleri, optimum eşikler ve bunlara karşılık gelen uygunluk değerleri Tablo 4.27'de verilmiştir.


Veri setinden rastgele on test görüntüsü seçilmiştir. Bu görüntüler için Orjinal Rao algoritmasının ve Rao algoritmasına uygulanan sekiz farklı kaotik haritanın hesaplama süreleri Şekil 4.15'de karşılaştırmalı olarak verilmiştir. Chebysev haritası ile geliştirilmiş Rao algoritmasının ve diğer beş farklı harita ile hesaplama süreleri karşılaştırılmıştır. Karşılaştırmalı sonuçlar Şekil 4.16'da verilmiştir. Şekil 4.16'da görüldüğü gibi Chebysev-Rao algoritması genellikle diğer algoritmalara göre daha kısa sürede global optimumu yakınsamaktadır.

Şekil 4.15'de, Circle ve Singer kaotik haritalarının diğerlerinden daha kötü olduğu görülmektedir. Rao algoritmasına Sinüzoidal ve Sinüs haritaları uygulandığında, kaotik olarak zenginleştirilmiş algoritmalar çoğunlukla basit Rao algoritmasına göre daha kısa sürede optimum noktayı yakınsamaktadırlar. Bununla birlikte, Chebyshev-Rao ve Logistic-Rao genellikle en kısa sürede


optimum noktaya yaklaşmaktadır. Gauss ve Tent haritaları, basit Rao algoritması ile rekabetçi sonuçlara sahiptir.

Tablo 4.27. Farklı kaotik haritalarla geliştirilen Rao algoritmaları ile elde edilen beş örnek görüntü için optimum değerler

Görüntü	Kaotik Harita	Optimum eşikler	Level	Varyans ($\times 10^3$)
Test Görüntü 1	Orjinal Rao1	43 76 94 102 123 174	6	3.7389
	Logistic Harita	43 76 94 102 123 174	6	3.7389
	Sine Harita	43 76 94 102 123 174	6	3.7389
	Sinusoidal Harita	43 76 92 102 124 174	6	3.7389
	Gauss Harita	41 76 92 122 174	5	3.7276
	Circle Harita	60 93 119 172	4	3.7029
	Chebyshev Harita	61 86 99 124 176	5	3.7272
	Singer Harita	62 92 132	3	3.6546
	Tent Harita	43 76 94 102 123 174	6	3.7389
Test Görüntü 2	Orjinal Rao1	84 120 135 148 171	5	6.3938
	Logistic Harita	84 120 135 148 171	5	6.3938
	Sine Harita	84 120 135 148 171	5	6.3938
	Sinusoidal Harita	84 120 135 148 171	5	6.3938
	Gauss Harita	84 124 147 171	4	6.3897
	Circle Harita	90 127 147 173 255	5	6.3858
	Chebyshev Harita	83 116 130 136 144 149 173	7	6.3928
	Singer Harita	83 111 149 174 255	5	6.3692
	Tent Harita	84 120 135 148 171	5	6.3938
Test Görüntü 3	Orjinal Rao1	38 90 114 127 172	5	11.989
	Logistic Harita	37 88 112 119 129 172	6	11.990
	Sine Harita	37 88 112 119 129 172	6	11.990
	Sinusoidal Harita	37 88 112 119 129 172	6	11.990
	Gauss Harita	38 92 114 123 169	5	11.985
	Circle Harita	26 84 126 173	4	11.934
	Chebyshev Harita	38 90 114 127 172	5	11.989
	Singer Harita	59 96 129 167	4	11.940
	Tent Harita	37 88 112 119 129 172	6	11.990
Test Görüntü 4	Orjinal Rao1	64 85 94 103 128 198	6	5.8503
	Logistic Harita	66 86 102 128 198	5	5.8494
	Sine Harita	64 85 94 103 128 198	6	5.8503
	Sinusoidal Harita	66 94 128 198	4	5.8385
	Gauss Harita	66 86 102 128 198	5	5.8494
	Circle Harita	63 97 121 200	4	5.8184
	Chebyshev Harita	66 94 128 198	4	5.8385
	Singer Harita	2 70 101 127 203	5	5.8290
	Tent Harita	64 85 94 103 128 198	6	5.8503
Test Görüntü 5	Orjinal Rao1	101 130 145 154 166 199	6	9.9925
	Logistic Harita	101 130 145 154 166 199	6	9.9925
	Sine Harita	101 130 145 154 166 199	6	9.9925
	Sinusoidal Harita	101 130 145 154 166 199	6	9.9925
	Gauss Harita	100 129 144 157 168 200	6	9.9907
	Circle Harita	97 133 142 201	4	9.9454
	Chebyshev Harita	101 130 146 160 167 200	6	9.9913
	Singer Harita	101 130 148 204	4	9.9695
	Tent Harita	101 130 145 154 166 199	6	9.9925



























Şekil 4.15. Rao algoritmasına uygulanan kaotik haritaların hesaplama süreleri (sn)



Şekil 4.16. CER algoritması ve diğer 5 algoritma için hesaplama süreleri (sn)

Önerilen CER algoritmasının etkinliğini göstermek için önerilen yöntemi diğer optimizasyon yöntemleriyle karşılaştırmak önemlidir. Çok seviyeli eşikleme problemini çözmek için farklı stratejilere ve formülasyonlara sahip DE, ABC ve GSA gibi farklı optimizasyon teknikleri kullanılmıştır. Bu teknikler biyoloji ve fizikten esinlenmiştir. 3-seviyeli ve 5-seviyeli olarak bölütlenmiş görüntüler, Şekil 4.17’de verilmiştir.

Metot	3-seviye			5-seviye		
	Görüntü 1	Görüntü 2	Görüntü 3	Görüntü 1	Görüntü 2	Görüntü 3
cRao						
ABC						
DE						
GSA						
eKGSA						
cKGSA						

Şekil 4.17. Bölütlenmiş görüntüler

Önerilen yöntemin kaotik davranışını değerlendirmek için, çok seviyeli eşikleme problemini çözmede kaotik güçlendirilmiş Kbest GSA (cKGSA) [160] yöntemi uygulanmıştır. BSDS300 veri setindeki tüm görüntüler için 12 ölçüm indeksine göre önerilen yöntem, DE, ABC, GSA, cKGSA, eKGSA yöntemleri ile karşılaştırmalı olarak Tablo 4.28’de verilmiştir. Verilen tablodaki ölçüm değerleri, verisetindeki tüm görüntülere uygulanıp ortalaması alınarak elde edilmiştir. Karşılaştırma sonucunda en iyi bulunan değerler tabloda koyu renk ile vurgulanmıştır. Tablodaki sonuçlar incelendiğinde, CER algoritması ile 12 indeksten 7’sinde en iyi sonucu bulurken, önerilen yöntemle en yakın ABC algoritması 12 indeksten 3’ünde en iyi sonucu elde etmiştir. Bununla birlikte, eKGSA yönteminde MD ve BDE indekslerinde başarı sonuçlar elde ederken DE ve GSA yöntemlerinin diğerlerine göre daha az başarı gösterdiği belirlenmiştir.

Tablo 4.28. Veri setindeki tüm görüntüler için 12 ölçüm indeksine göre farklı algoritmaların karşılaştırılması

	CER	DE	ABC	GSA	cKGSA	eKGSA
BDE	10.7019	10.4109	10.456	10.2567	10.2719	10.2407
PRI	0.6572	0.5993	0.6016	0.6073	0.6070	0.6079
VOI	3.2499	2.7882	2.7828	2.8067	2.8060	2.8078
GCE	0.4523	0.3247	0.3238	0.3348	0.3345	0.3352
SSIM	0.5771	0.4549	0.4423	0.5258	0.4529	0.4529
FSIM	0.7206	0.6779	0.6697	0.5902	0.6749	0.6742
RMSE	37.0342	49.8913	51.1517	43.3015	50.0514	50.0259
PSNR	17.1568	14.4306	14.2079	15.6764	14.4014	14.4092
CC	0.7584	0.6414	0.6369	0.6414	0.6517	0.6532
AD	28.6930	43.7985	44.2451	42.7436	42.7141	42.5637
MD	113.4300	111.1072	113.7159	110.9021	110.9258	110.8570
NAE	0.2748	0.422	0.4257	0.4100	0.4099	0.4080

300 test görüntüsünün ortalama PRI, SSIM, FSIM, RMSE, PSNR, AD ve NAE değerleri dikkate alınarak yapılan istatistiksel analizden, önerilen CER algoritmasının optimum eşik değerleri elde etmede daha etkin olduğu görülmüştür.

4.4. PSO Algoritması ile Çok Seviyeli Görüntü Eşikleme

Önerilen algoritmanın optimum eşik değerlerini belirlemedeki etkinliğini vurgulamak için farklı histogramlara sahip veri setindeki 300 test görüntüsü kullanılarak deneyler yapılmıştır. Yöntemin etkililiği, literatürde yaygın kullanılan 12 görüntü kalitesi ölçüm indeksi kullanılarak gerçekleştirilmiştir. Önerilen yöntem kullanılarak elde edilen değerler CPU süresi ile birlikte objektif değerler, DE [161], ABC [162], GSA [89], KGSA [46], cKGSA [160] gibi metasezgisel yöntemlere dayanan hali hazırda bildirilen çok seviyeli eşikleme algoritmalarıyla karşılaştırılır. Yaklaşımın performansı verisetindeki referans görüntüler kullanılarak değerlendirilir.

PSO tabanlı çok seviyeli görüntü eşikleme yaklaşımı, 2.4 GHz ve Intel(R) çift çekirdekli işlemcili ve Microsoft Windows 10 sistemi ile 2 GB belleğe sahip bir bilgisayarda MATLAB'da simülasyonlarla doğrulanmıştır. Önerilen PSO tabanlı eşikleme yaklaşımında kullanılan parametre değerleri Tablo 4.29'da gösterilmektedir. Geliştirilen yöntemde amaç fonksiyonu olarak Renyi'nin entropisi yöntemi kullanılmıştır. Önerilen PSO tabanlı çok seviyeli eşikleme algoritması 30 kez çalıştırılmış ve sonuçlar 30 değerlerin ortalaması alınarak sunulmuştur. Parametrelerin doğru ayarlanması algoritmanın etkililiğini göstermede kritik önem taşımaktadır. Adil bir mukayese yapabilmek için eşikleme yöntemi için tüm parametre değerleri aynı şekilde kullanılmıştır. Bu kapsamda; maksimum iterasyon sayısı, popülasyon boyutu, alt ve üst sınır değerleri, parçacık sayıları gibi parametre değerleri eşit kullanılmıştır. Bu parametrelerin değerleri Tablo 4.29'da sunulmuştur. Tablodan da görüleceği üzere başlangıç popülasyonu problem boyutu (eşik seviye sayısı) ve parçacık sayısına dayalı olarak oluşturulmaktadır. Örneğin, eşik seviye sayısı 3 ve parçacık sayısı 10 olan bir popülasyon boyutu 3×10 olacaktır.

Tablo 4.29. Çok seviyeli eşikleme için kullanılan algoritma parametreleri

Parametreler	Değerleri
Problem boyutu	Eşik seviyesi
Alt sınır	0
Üst sınır	255
Sürüdeki parçacık sayısı	100
Popülasyon boyutu	Parçacık boyutu * parçacık sayısı
İterasyon sayısı	1000
Hızlandırma faktörleri ($c1$, $c2$)	0.12,1.2
Momentum katsayısı (w)	0.9
Eşik seviye sayıları	3 seviye, 5 seviye

Literatürde, görüntü bölütleme işlemlerinin performansını değerlendirmede çok sayıda kalite ölçüm indeksi kullanılmaktadır. En yaygın kullanılan indeksler BDE, PRI, GCE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD, NAE ve MD'dir. Bu çalışmada, belirtilen indeksler ile önerilen bölütleme yönteminin başarımı değerlendirilmiştir. Veri setindeki 300 görüntü için elde edilen değerlerin ortalaması alınarak sonuçlar sunulmuştur. Görüntülere 3-seviyeli ve 5-seviyeli bölütleme yapıldığı durumda sağlanan ölçüm indeksleri, literatürdeki mevcut çalışmalarla mukayese edilerek Tablo 4.30 ve Tablo 4.31'de sunulmaktadır. Tablolarda, en iyi değerler koyu renkle vurgulanmıştır.

Tablo 4.30. 3-seviyeli görüntü eşikleme için önerilen yöntemin diğer yöntemlerle karşılaştırması

Yöntem	Önerilen Yöntem	GSA	cKGSA	eKGSA	DE	ABC
BDE	9.9713	10.256	10.271	10.240	10.410	10.456
PRI	0.6130	0.6073	0.6070	0.6079	0.5993	0.6016
VOI	2.8057	2.8067	2.8060	2.8078	2.7882	2.7828
GCE	0.3391	0.3348	0.3345	0.3352	0.3247	0.3238
SSIM	0.5258	0.4529	0.4529	0.4549	0.4423	0.4398
FSIM	0.5902	0.6749	0.6742	0.6779	0.6697	0.6691
RMSE	43.301	50.051	50.025	49.891	51.151	51.706
PSNR	15.676	14.401	14.409	14.430	14.207	14.161
CC	0.8824	0.6414	0.6517	0.6532	0.6414	0.6369
AD	36.769	42.743	42.714	42.563	43.798	44.245
MD	94.500	110.90	110.92	110.85	111.10	113.71
NAE	0.3670	0.4100	0.4099	0.4080	0.4220	0.4257

Tablo 4.30'da görüldüğü üzere, önerilen yöntem BDE, PRI, SSIM, RMSE, PSNR, AD, CC, MD, NAE indeksi olmak üzere dokuz görüntü kalitesi ölçüm indeksinde diğer yöntemlere göre daha başarılı bulunmuştur. Bununla beraber, ABC algoritması ile yapılan bölütleme işlemleri VOI ve GCE indekslerinde en iyi sonucu elde ederken eKGSA algoritması FSIM indeksinde 300 görüntü üzerinden yapılan bölütlemelerde iyi sonuç vermiştir.


Tablo 4.31'de 5-seviyeli olarak bölütlenen görüntülerin kalite ölçümlerinde önerilen yöntemin, 12 indeksten sekizinde (BDE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD) daha iyi sonuçlar elde ettiği gösterilmiştir. Ek olarak, eKGSA'ya dayalı yapılan bölütlemelerde PRI ve NAE

indekslerinde, DE ile yapılan bölütlemeye GCE ve GSA ile yapılan bölütleme de MD indeksinde başarılı sonuçlar elde edilmiştir.

Tablo 4.31. 5-seviyeli görüntü eşikleme için önerilen yöntemin diğer yöntemlerle karşılaştırması


Yöntem	Önerilen Yöntem	GSA	cKGSA	eKGSA	DE	ABC
BDE	9.7782	9.9448	9.8978	9.8776	10.086	9.9355
PRI	0.6591	0.6610	0.7010	0.7261	0.6450	0.6553
VOI	3.0255	3.1415	3.1419	3.1436	3.0676	3.1283
GCE	0.4401	0.4396	0.4391	0.4397	0.4124	0.4332
SSIM	0.6654	0.6566	0.6569	0.6428	0.5980	0.6428
FSIM	0.7910	0.7857	0.7858	0.7800	0.7549	0.6428
RMSE	29.233	29.386	29.424	29.392	35.107	30.945
PSNR	19.040	18.951	18.941	18.946	17.565	18.596
CC	0.9743	0.8006	0.8004	0.8000	0.7629	0.7888
AD	24.688	24.933	24.960	24.899	29.466	26.135
MD	71.550	69.521	69.893	70.183	79.765	73.260
NAE	0.2427	0.2419	0.2420	0.2412	0.2878	0.2557

Şekil 4.18 ve Şekil 4.19, önerilen yöntemin hesaplama verimliliğini göstermektedir. PSO tabanlı çok seviyeli eşikleme algoritması, yakınsama süresine (ortalama olarak saniye cinsinden alınan CPU süresi) dayalı olarak eKGSA yöntemiyle karşılaştırılır. Tablo 4.30 ve Tablo 4.31’de karşılaştırılan diğer yöntemlere nazaran eKGSA daha başarılı olduğundan hesaplama verimliliği karşılaştırmaları için bu yöntem seçilmiştir. Şekil 4.18 ve Şekil 4.19’dan, önerilen PSO tabanlı çok seviyeli eşikleme yönteminin, eKGSA yöntemine göre daha hızlı olduğu açıkça görülmektedir.



Şekil 4.18. 3 seviyeli eşiklemede PSO ve e-KGSA yöntemlerinin hesaplama süreleri (sn)

Genel olarak inceleyecek olursak; BDE indeksi, iki görüntü arasındaki hatayı hesaplamaktadır. Bu değer ne kadar küçük olursa bölütleme performansı da o kadar iyi olacaktır. Önerilen 2DYOHO-PSO yöntemi ile 3-seviyeli olarak gerçekleştirilen bölütleme işleminde literatürde var olan yöntemlere kıyasla, BDE indeksinde %2.63 oranında gelişme görülmüştür.




Şekil 4.19. 5 seviyeli eşiklemede PSO ve e-KGSA yöntemlerinin hesaplama süreleri (sn)

PRI ve SSIM indeksleri bölütleme performansını belirleyen indeksler olup bu değerlerin yüksek olması daha iyi bir bölütleme performansını ifade etmektedir. Önerilen yöntem ile 3-seviyeli olarak gerçekleştirilen bölütleme işleminde bu indekslerde sırasıyla % 0.83 ve %15.5 oranında iyileşme sağlanmıştır. RMSE, AD, MD, NAE istatistiksel ölçüm indeksleri olup sırasıyla % 13.2, %13.9, %14.75 ve %10 oranında gelişme sağlanmıştır. Bununla beraber, önerilen yöntem ile 5-seviyeli olarak gerçekleştirilen bölütleme işleminde literatürde var olan yöntemlere kıyasla, BDE ve FSIM indeksinde sırasıyla %1 ve %0.85 gelişme görülürken, RMSE ve PSNR indekslerinde sırasıyla %15.35 ve %8.88 oranında iyileşme görülmüştür. Ayrıca, CC e AD gibi istatistiksel hatayı gösteren indekslerde, sırasıyla %17.36 ve %12.8 oranında gelişme olduğu görülmüştür.

4.5. PS-VTS Yöntemi ile Deri Kanseri Görüntülerinin Bölütlenmesi

Bu bölümde, PS-VTS algoritmasının deneysel çalışmaları ve sonuçları açıklanmaktadır. İlk olarak, optimizasyon algoritmasını farklı açılardan değerlendirmek için çeşitli özelliklere sahip fonksiyonlardan oluşan 50 test fonksiyonu kullanılmıştır. Fonksiyonların detayları Ek- 1-3'te verilmiştir. Bununla birlikte, önerilen yöntemin çok seviyeli eşiklemede üzerindeki performansını değerlendirmek amacıyla ISIC2017 veri setinden on cilt kanseri görüntüsü kullanılmıştır. Seçilen test görüntüleri Şekil 4.20'de sunulmuştur. Görüntüler Test Görüntüsü1, Test Görüntüsü2 vb. olarak belirtilmiştir. Şekil 4.21, görüntülerin 1D ve 2D histogramlarını göstermektedir. Önerilen yöntemin performansı yedi yeni meta sezgisel yöntemle karşılaştırılmıştır. Bu yöntemler: AOA [102], GWO [124], MFO [163], WOA [114], MVO [164], TLBO [127] ve orijinal PSO [108]'dur. Tüm algoritmalar, çok seviyeli eşikleme için 1000 iterasyonlu 20 çalıştırma üzerinde test edilir. Görüntüler 2, 3, 4 ve 5 eşik seviyeleri ile bölümlere ayrılmıştır. Bölütlenmiş görüntülerin başarımları, SSIM, FSIM ve PSNR metrikleri kullanılarak değerlendirilir.



Şekil 4.20. Çalışmada kullanılan test görüntüleri.

Deneysel çalışmalar, Windows 10 ortamında, Intel core-i7 (9. Nesil) işlemci ve 16 GB RAM'e sahip Matlab 2020a üzerinde gerçekleştirilmiştir. Önerilen yöntem yedi güncel algoritma ile karşılaştırılmıştır. Bunlar: PSO, AOA, GWO, WOA, TLBO, MFO ve MVO algoritmalarıdır. Algoritmalar, her test görüntüsü için 30 kez çalıştırılmıştır. Tüm algoritmalar için popülasyon büyüklüğü ve maksimum iterasyon sayısı, sırasıyla, 20 ve 1000 olarak ayarlanmıştır. Önerilen yöntemde kullanılan diğer parametre değerleri ise Tablo 4.32'de verilmiştir. Parametre değerleri, kullanılan tüm optimizasyon algoritmalarında aynıdır.


Tablo 4.32. Bölütleme yönteminde kullanılan parametre değerleri

Parametre	Değer
W	0.8
C ₁ , C ₂	0.6, 1.2
N _{pop}	20
Max _{iter}	1000
Runs	30

**W= Atalet momenti; C₁,C₂= Hızlandırma faktörleri; N_{pop} = Parçacık sayıları; Max_{iter}= Maksimum iterasyon sayısı; Runs= Çalıştırma sayısı


Test Fonksiyonları Üzerinde Deneysel Çalışmalar ve Sonuçlar:

Önerilen PS-VTS yönteminin performansı, optimizasyon algoritmasını farklı açılardan değerlendirmek için çeşitli özelliklere sahip fonksiyonlardan oluşan 50 kıyaslama fonksiyonu ile test edilmiştir. Sonuçlar analiz edilerek diğer optimizasyon algoritmalarıyla karşılaştırılır. Kullanılan kıyaslama fonksiyonları Ek- 1-3'te verilmiştir. Bahsedilen test fonksiyonlarından 36 tanesi ayrılmaz (nonseparable), 14 tanesi ayrılabilir (separable), 17 tanesi tek modlu (unimodal) ve 33 tanesi çok modludur (multimodal).




Şekil 4.21. (a) Deri kanseri görüntüleri görüntüleri, (b) 1D histogram, (c) 2D histogram

Nitel Analiz: Önerilen yöntemin performansını doğrulamak için, bu bölümde nitel analiz yapılmıştır. Test fonksiyonları, 2 tek modlu (Sphere ve Rosenbrock) ve 3 çok modlu (Griewank, Ackley ve Rastrigin) fonksiyonları içermektedir. Nitel analiz için, (a) fonksiyonların genel görünümü, (b) 1. boyutta yörünge ve (c) her fonksiyon için global en iyi parçacığın yakınsama eğrisini içeren üç alt şekil, Şekil 4.22’de verilmiştir.



Şekil 4.22. Nitel analiz özeti,(a)Test fonksiyonları, (b) 1-boyutta yörünge,(c) Yakınsama eğrisi.



Şekil 4.23. Test fonksiyonlarının farklı algoritmalar ile yakınsama grafikleri


Tüm algoritmalar için 2 adet tek modlu (Sphere-F3 ve Rosenbrock-F16) ve 3 adet çok modlu (Griewank-F41, Ackley-F42 ve Rastrigin-F22) fonksiyonların yakınsama eğrileri karşılaştırmalı olarak Şekil 4.23'te sunulmuştur. Fonksiyonlar için boyut ve iterasyon sayısı sırasıyla 30 ve 1000 olarak ayarlanmıştır. Önerilen PS-VTS algoritmasının bu tek modlu ve çok modlu fonksiyonlar için en hızlı yakınsamayı sağladığı Şekil 4.23'te görülmektedir.

Nicel Analiz: Önerilen yöntem ile gerçekleştirilen istatistiksel analizler Ek- 4-6'da sunulmaktadır. Sonuçlar, her test işlevi için 30 bağımsız çalışma ile sağlanmıştır. 30 çalıştırma sonrasında elde edilen ortalama değerlere göre PS-VTS yöntemi uygulanan test fonksiyonlarının %60'ında başarılı olmuştur. Bununla birlikte, test fonksiyonlarının PSO %18'inde, AOA %20'sinde, GWO %30'unda, MFO %26'sında, WOA %24'ünde, MVO %18'inde ve TLBO %48'inde başarılı olmuştur. 30 çalıştırmadan sonra elde edilen minimum değerlere göre PS-VTS yöntemi %62 ve PSO %18, AOA %20, GWO %30, MFO %26, WOA %24, MVO %18 ve TLBO %48 oranında başarılı olmuştur. Maksimum değerlere göre, PS-VTS yöntemi uygulanan test fonksiyonlarının %42'sinde başarılı olmuştur. Bununla birlikte, PSO %20, AOA %26, GWO %26, MFO %26, WOA %16, MVO %18 ve TLBO %56 oranında diğer yöntemlere göre daha başarılı olmuştur. Standart sapma değerlerine göre ise PS-VTS yöntemi 50 kıyaslama fonksiyonunun %46'sında ve PSO %18'inde, AOA %20'sinde, GWO %14'inde, MFO %18'inde, WOA %12'sinde, MVO %4'ünde ve TLBO %48'inde başarılı olmuştur.

Ölçülebilirlik Analizi: Bu bölüm, önerilen algoritmayı farklı boyutlardaki problemlere sahip diğer algoritmalar ile değerlendirir. Ortalama ve standart sapma açısından 3 boyut (D=10, D=50 ve D=100) ile 25 test fonksiyon üzerinde gerçekleştirilen deneysel sonuçlar Ek- 7-9'da verilmiştir. Önerilen yöntem D=10 için ortalama değerlerde 25 fonksiyonun 10'unda birinci, 5'inde ikinci sırada yer alırken, standart sapma değerlerinde fonksiyonların 10'unda birinci, 7'sinde ikinci sırada yer almıştır. Önerilen yöntem D=50 için 25 fonksiyonun 12'sinde birinci ve 5'inde ikinci sırada yer alırken, standart sapma değerlerinde fonksiyonların 12'sinde birinci ve 11'inde ikinci sırada yer almıştır. Son olarak, D=100 için PS-VTS sırasıyla 14 test fonksiyonunda en iyi ortalamayı ve 7 test fonksiyonunda en iyi standart sapmayı elde etmiştir.

Deri Kanseri Görüntülerinde Çok Seviyeli Eşikleme Uygulaması

Önerilen PS-VTS optimizasyon algoritmasının etkinliğini daha fazla göstermek için, ISIC2017 veri setinden elde edilen 10 cilt kanseri görüntüsü kullanılarak çok seviyeli eşikleme gerçekleştirilmiştir. Amaç fonksiyonu olarak Renyi'nin entropisi kullanılmıştır. Önerilen PS-VTS yöntemiyle bölütlenmiş görüntüler, değişen eşik seviyeleri [$n = 2, 3, 4$ ve 5] ile Şekil 4.24'te gösterilmektedir. Deneysel sonuçlar, son teknoloji yöntemlerle (PSO, AOA, GWO, MFO, WOA, MVO ve TLBO) karşılaştırılmıştır. Önerilen yöntem ve diğer metasezgisel yöntemlerle elde edilen en iyi eşikler Tablo 4.33 ve Tablo 4.34'te sunulmaktadır.



Şekil 4.24. PS-VTS algoritması ile bölütlenen görüntüler: (a) Orjinal görüntüler, (b) 2-seviyeli, (c) 3-seviyeli, (d) 4-seviyeli, and (e) 5-seviyeli olarak bölütlenmiş görüntüler.

SSIM, FSIM ve PSNR değerlendirme metriklerinin ortalama değerleri sırasıyla Tablo 4.35 - Tablo 4.37’de gösterilmektedir. Daha yüksek SSIM, FSIM ve PSNR ortalama değerleri, daha doğru ve verimli çok seviyeli eşikleme yöntemleri ile gerçekleştirilen bölütlemeleri göstermektedir. 30 çalıştırma için ortalama SSIM değerleri Tablo 4.35’te verilmiştir; daha yüksek bir SSIM değeri, daha iyi bir segmentasyon sonucunu temsil etmektedir. PS-VTS algoritması, neredeyse tüm eşik seviyeleri ve tüm görüntüler için orijinal PSO ve AOA’dan daha iyi performans göstermiştir. GWO, bazı görüntüler için yalnızca eşik seviyesi-2’de PS-VTS yöntemiyle rekabetçi sonuçlara sahip olmuştur. MFO, eşik seviyeleri 2 ve 4 için Test Görüntüleri-6 ve-7’de PS-VTS’ye göre daha iyi sonuçlar verildiği görülmüştür.

Tablo 4.33. Tüm seviyeler için elde edilen Renyi'nin optimum eşik değerleri (Görüntü 1- Görüntü 5)

Test Görüntüsü	nTh	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
1	2	20,110	89,152	191,236	20,110	20,105	20,110	20,110	20,110
	3	20,76,132	20,84,154	132,177,241	20,76,132	20,75,131	20,76,132	20,77,133	20,76,732
	4	14,58,95,133	118,160,199,235	88,169,207,236	20,59,97,134	20,56,94,132	20,58,96,134	20,58,95,133	20,56,91,126
	5	20,49,77,105,133	88,130,165,201,235	98,148,203,225,254	20,50,79,107,135	20,44,68,93,117	20,50,80,110,140	20,49,78,106,133	20,48,76,105,134
2	2	14,75	116,218	112,214	14,110	20,105	14,110	14,110	14,110
	3	14,68,121	98,159,218	101,151,232	14,65,121	20,75,131	14,62,121	14,68,121	14,68,121
	4	14,54,94,134	82,129,174,218	104,155,203,249	14,51,89,129	20,56,94,132	14,53,93,133	14,53,93,133	14,44,75,116
	5	14,43,73,103,133	70,113151,189,226	82,131,157,186,223	14,41,68,98,127	20,44,68,93,117	14,43,73,102,131	14,44,74,104,134	14,42,70,98,128
3	2	53,113	143,199	148,187	53,113	50,100	48,113	53,113	53,113
	3	44,88,132	53,155,210	21,77,186	42,86,132	40,79,120	40,86,132	44,88,132	41,81,121
	4	34,67,100,134	53,133,174,215	29,51,172,190	32,66,100,134	31,62,94,120	47,94,141,185	35,69,103,137	32,64,97,133
	5	28,56,84,112,140	30,67,3141,181,220	41,98,131,150,227	22,53,81,110,138	22,47,71,98,125	28,56,84,112,140	29,56,84,111,138	27,53,79,106,134
4	2	20,116	139,240	147,240	20,116	20,131	20,121	20,116	20,103
	3	20,78,135	138,189,240	120,221,248	20,78,136	20,73,125	20,78,136	20,78,136	20,78,136
	4	20,59,98,134	20,67,114,168	108,172,224,250	20,57,94,133	20,54,88,121	20,59,98,137	20,59,98,137	20,57,95,134
	5	20,48,77,106,134	55,88,126,162,197	96,148,166,212,243	20,50,78,107,136	20,51,81,112,143	20,50,78,106,134	20,46,73,100,127	20,41,63,98,132
5	2	48,97	130,204	48,86	48,97	49,105	49,68	48,97	48,97
	3	47,94,141	38,87,204	133,170,212	45,93,141	56,89,140	47,94,141	47,94,141	47,94,141
	4	35,70,106,140	49,143,185,221	151,173,213,236	30,63,97,132	31,62,93,124	33,66,98,134	35,70,105,140	33,65,98,133
	5	28,55,82,109,136	39,87,164,196,233	32,125,167,216,239	17,43,72,102,132	24,51,79,106,133	27,54,81,108,136	27,54,81,108,137	23,49,76,104,132

Tablo 4.34. Tüm seviyeler için elde edilen Renyi'nin optimum eşik değerleri (Görüntü 6- Görüntü 10)

Test Görüntüsü	nTh	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
6	2	26,113	139,217	11,219	26,113	26,113	26,113	26,113	26,113
	3	26,80,134	134,176,218	94,170,233	26,80,134	26,76,126	26,80,134	26,80,134	24,80,134
	4	26,62,98,134	26,142,190,224	139,183,194,235	25,62,98,134	25,63,102,141	26,62,98,134	26,61,97,134	26,63,101,138
	5	26,53,80,108,135	22,52,153,184,220	58,139,161,210,254	23,51,79,107,135	24,52,79,107,135	26,54,81,108,136	26,53,80,107,134	25,51,77,105,134
7	2	23,110	147,221	177,221	23,110	23,110	23,110	23,110	23,110
	3	23,78,133	127,174,221	144,196,222	23,78,133	23,76,129	23,77,133	23,78,133	23,78,133
	4	23,61,100,138	66,141,186,222	129,183,213,253	23,61,99,137	23,61,99,138	23,61,100,138	23,60,97,134	23,61,99,137
	5	23,51,79,108,136	23,414,180,210,233	19,101,152,188,236	18,43,71,100,128	21,44,67,92,117	23,51,79,107,135	23,51,79,106,134	23,51,80,110,140
8	2	24,94	125,192	132,195	24,94	24,94	24,94	24,99	24,99
	3	24,72,119	113,160,209	92,193,222	24,75,126	24,63,102	24,69,126	24,75,126	24,75,126
	4	24,58,93,127	80,125,173,215	119,203,215,239	24,58,92,127	24,53,83,113	18,52,99,127	24,58,93,127	24,58,93,127
	5	24,50,75,100,127	24,113,146,194,225	55,148,173,212,230	20,44,69,98,127	21,42,69,96,123	12,40,69,97,127	24,49,74,100,127	23,49,75,101,132
9	2	18,109	137,206	107,208	18,109	18,95	18,109	18,109	18,109
	3	18,74,130	126,168,212	94,171,224	18,72,128	18,67,116	18,74,130	18,73,128	18,74,130
	4	18,57,96,135	92,137,177,218	118,164,191,211	18,56,94,134	17,49,82,114	18,57,96,135	18,55,94,133	18,57,96,135
	5	18,47,76,105,134	17,57,113,190,224	72,136,209,220,254	18,47,74,103,131	18,47,76,104,132	18,47,76,105,134	18,45,73,101,129	18,44,71,101,132
10	2	56,111	61,121	88,191	55,111	56,111	60,120	70,140	55,111
	3	47,94,141	59,121,190	161,188,212	47,94,141	48,97,146	47,94,141	47,94,140	47,94,141
	4	35,70,105,140	54,106,150,190	63,100,203,230	33,66,102,138	35,64,96,129	35,70,105,140	35,70,106,141	34,69,104,139
	5	28,56,84,112,140	39,77,115,181,220	41,70,110,151,193	28,55,84,113,141	24,50,77,103,126	29,57,85,113,141	28,55,82,109,137	28,56,84,112,140

PS-VTS, geri kalan görüntülerde neredeyse tüm eşik seviyelerinde MFO'dan daha yüksek SSIM değerlerine sahiptir. WOA, Test Görüntüsü-9'da iyi performans gösterirken PS-VTS, kalan test görüntülerinin çoğunda daha iyi performans göstermiştir. MVO ve TLBO yöntemlerinin, önerilen yöntemle 2 ve 3 eşik seviyelerinde rekabetçi sonuçlara sahip olduğu görülmüştür.

Tablo 4.36, her cilt kanseri görüntüsü için ortalama FSIM değerlerini sunmaktadır. Daha verimli algoritma daha yüksek bir FSIM değerine sahip olmalıdır. PS-VTS yöntemi, orijinal PSO ve AOA yöntemleri ile karşılaştırıldığında, önerilen yöntemin hemen hemen tüm görüntüler ve eşik seviyeleri için daha yüksek ortalama FSIM değerlerine sahip olduğu görülmektedir. PSO, Test Görüntüleri-1 ve 2 için eşik seviyesi 2'de daha iyi sonuçlara sahiptir. GWO, Test Görüntüleri-1, 4, 6 ve 7 için eşik seviyesi 3'te daha iyi performans göstermiştir. MFO ve MVO algoritmaları da bazı test görüntüleri için eşik seviyesi 2 ve 3'te iyi performans göstermiştir. TLBO, test görüntüleri-3, 5 ve 6'da PS-VTS yöntemi ile rekabetçi sonuçlara sahiptir. Tablo 4.37, her görüntü için ortalama PSNR değerlerini göstermektedir. PS-VTS'nin tüm görüntülerde neredeyse tüm eşik seviyelerinde diğer algoritmalarından daha iyi performans gösterdiği görülmektedir. Orijinal PSO, Test görüntüsü 3, 5 ve 10 için eşik seviyesi 3'te iyi performans göstermiştir. AOA ise Test görüntüsü 1 ve 2 için eşik seviyesi 4'te iyi performans göstermiştir. Diğer algoritmalar, tüm test görüntülerinde ve eşik seviyelerinde önerilen yöntemden daha düşük PSNR dolayısıyla daha düşük bir bölütleme performansına sahiptir.

Tüm cilt kanseri görüntüleri için ortalama SSIM değerleri Şekil 4.25'te gösterilmektedir. Değerler, 30 çalışma üzerinden 10 cilt kanseri görüntüsünün SSIM indeksinin ortalaması alınarak elde edilmiştir. Bu şekilden, PS-VTS yönteminin daha yüksek SSIM değerlerine sahip olduğu ve bunun daha iyi çok seviyeli bölütleme performansına işaret ettiği not edilebilir. Ayrıca SSIM değerlendirme metriğinin değerinin eşik seviyesi ile beraber yükseldiği görülmektedir. PS-VTS eşik 2'de 0,7278, eşik 3'te 0,7862, eşik 4'te 0,8125 ve eşik 5'te 0,8285 ile daha iyi bölütleme performansları elde etmiştir.

FSIM'in ortalama değerleri Şekil 4.26'da gösterilmektedir. Değerler, 30 bağımsız çalışma üzerinden tüm cilt kanseri görüntülerinin FSIM değerlerinin ortalaması alınarak elde edilmiştir. Önerilen yöntemle elde edilen FSIM değerleri, 2-seviyede 0.7019 ile, 3-seviyede 0.7112 ile, 4-seviyede 0.7229 ile ve 5-seviyede 0.7332 ile diğer karşılaştırılan algoritmalar tarafından elde edilen FSIM değerlerinden daha yüksek değerlere ulaşmıştır. AOA ve TLBO yöntemleri kalan diğer algoritmalarla göre daha yüksek FSIM değerlerine ulaşmıştır.

Tablo 4.35. Ortalama SSIM deęerleri.

Test Görüntüsü	nTh	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
Görüntü 1	2	0,5954	0,5262	0,3544	0,5954	0,5873	0,5954	0,5954	0,5954
	3	0,6743	0,6769	0,4788	0,6742	0,6737	0,6742	0,6742	0,6742
	4	0,7179	0,4612	0,4444	0,7181	0,7196	0,7191	0,7179	0,7122
	5	0,7552	0,5120	0,4377	0,7551	0,7396	0,7604	0,7551	0,7586
Görüntü 2	2	0,7992	0,7914	0,7824	0,6555	0,6555	0,7992	0,7992	0,7992
	3	0,8398	0,8135	0,8395	0,8395	0,8469	0,8394	0,8398	0,8398
	4	0,8713	0,6280	0,8316	0,8655	0,8171	0,8704	0,8704	0,8420
	5	0,8805	0,8576	0,8529	0,8725	0,7656	0,8789	0,8829	0,8741
Görüntü 3	2	0,7772	0,6848	0,5852	0,7772	0,7468	0,7743	0,7772	0,7772
	3	0,8023	0,4710	0,6525	0,8014	0,7967	0,8002	0,8023	0,7979
	4	0,8176	0,7671	0,4467	0,8170	0,8069	0,7937	0,8169	0,8161
	5	0,8252	0,7784	0,7999	0,8254	0,8185	0,8252	0,8270	0,8257
Görüntü 4	2	0,6962	0,6172	0,6284	0,6962	0,7292	0,7082	0,6962	0,6604
	3	0,7668	0,6763	0,5005	0,7668	0,7433	0,7668	0,7648	0,7668
	4	0,7875	0,8299	0,5681	0,7804	0,7516	0,7875	0,7875	0,7826
	5	0,7938	0,7520	0,6689	0,7979	0,8130	0,7930	0,7778	0,7973
Görüntü 5	2	0,7247	0,6722	0,6918	0,7247	0,7473	0,7288	0,7247	0,7247
	3	0,8093	0,6847	0,6559	0,8074	0,8084	0,8093	0,8093	0,8093
	4	0,8205	0,6517	0,6275	0,8162	0,8088	0,8181	0,8205	0,8179
	5	0,8372	0,7455	0,7534	0,8227	0,8316	0,8364	0,8367	0,8284
Görüntü 6	2	0,6408	0,5197	0,5124	0,6408	0,6408	0,6408	0,6408	0,6408
	3	0,703	0,5459	0,5867	0,7030	0,6960	0,7030	0,7030	0,7030
	4	0,7543	0,6487	0,5307	0,7526	0,7564	0,7543	0,7552	0,7564
	5	0,786	0,7323	0,7100	0,7832	0,7842	0,7862	0,7847	0,7846
Görüntü 7	2	0,6838	0,6658	0,6708	0,6838	0,6838	0,6838	0,6838	0,6838
	3	0,7662	0,7072	0,6704	0,7662	0,7574	0,7662	0,7662	0,7662
	4	0,7917	0,7427	0,5674	0,7900	0,7920	0,7917	0,7845	0,7900
	5	0,8086	0,6401	0,8033	0,7909	0,7642	0,8066	0,8044	0,8171
Görüntü 8	2	0,8085	0,8398	0,8376	0,8085	0,8085	0,8085	0,8259	0,8259
	3	0,8899	0,5637	0,7682	0,8899	0,8446	0,8885	0,8827	0,8899
	4	0,9019	0,8599	0,8351	0,9017	0,8806	0,8983	0,9019	0,9019
	5	0,9098	0,8855	0,8190	0,9085	0,9046	0,9076	0,9102	0,9098
Görüntü 9	2	0,7252	0,6966	0,6679	0,7252	0,6895	0,7252	0,7252	0,7252
	3	0,7857	0,7244	0,7171	0,7858	0,7694	0,7886	0,7886	0,7886
	4	0,8195	0,6952	0,6667	0,8185	0,7893	0,8195	0,8177	0,8195
	5	0,8398	0,6459	0,7566	0,8353	0,8372	0,8398	0,8325	0,8369
Görüntü 10	2	0,8266	0,7879	0,7748	0,8269	0,8269	0,7901	0,7798	0,8266
	3	0,8247	0,7857	0,2974	0,8223	0,8174	0,8223	0,8223	0,8223
	4	0,8429	0,8140	0,8182	0,8431	0,8355	0,8429	0,8416	0,8437
	5	0,8485	0,7969	0,8087	0,8450	0,8499	0,8458	0,8533	0,8485


Tablo 4.36. Ortalama FSIM değerleri

Test Görüntüsü	nTh	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
Görüntü 1	2	0,6886	0,6947	0,6803	0,6886	0,6861	0,6886	0,6886	0,6886
	3	0,7029	0,6978	0,6983	0,7031	0,7031	0,7031	0,7028	0,7031
	4	0,6939	0,7068	0,7305	0,7300	0,7342	0,7311	0,7305	0,7309
	5	0,7623	0,7236	0,6980	0,7583	0,7505	0,7583	0,7579	0,7612
Görüntü 2	2	0,7023	0,7023	0,7021	0,7022	0,6961	0,7022	0,6961	0,7022
	3	0,7056	0,7102	0,7063	0,7047	0,7052	0,7043	0,7052	0,7052
	4	0,7384	0,7113	0,7073	0,7081	0,7078	0,7071	0,7071	0,7091
	5	0,7131	0,7530	0,7475	0,7141	0,7067	0,7127	0,7130	0,7134
Görüntü 3	2	0,6208	0,6197	0,6207	0,6208	0,6187	0,6203	0,6208	0,6208
	3	0,6256	0,5455	0,6133	0,6294	0,6299	0,6289	0,6298	0,6263
	4	0,6620	0,6689	0,6349	0,6346	0,6287	0,6309	0,6355	0,6343
	5	0,6415	0,6387	0,7426	0,6409	0,6347	0,6415	0,6419	0,6387
Görüntü 4	2	0,7302	0,7284	0,7279	0,7302	0,7299	0,7302	0,7302	0,7302
	3	0,7434	0,7335	0,7149	0,7434	0,7434	0,7434	0,7434	0,7434
	4	0,7382	0,7544	0,7574	0,7577	0,7569	0,7574	0,7574	0,7579
	5	0,7694	0,7718	0,7476	0,7700	0,7714	0,7699	0,7686	0,7706
Görüntü 5	2	0,7037	0,7046	0,7016	0,7037	0,7056	0,7045	0,7037	0,7037
	3	0,7138	0,6990	0,7102	0,7131	0,7133	0,7133	0,7133	0,7133
	4	0,7116	0,7119	0,7165	0,7158	0,7152	0,7166	0,7166	0,7163
	5	0,7231	0,7452	0,7094	0,7190	0,7213	0,7231	0,7228	0,7207
Görüntü 6	2	0,7104	0,7047	0,7072	0,7104	0,7104	0,7104	0,7104	0,7104
	3	0,7244	0,7075	0,7152	0,7244	0,7229	0,7244	0,7244	0,7244
	4	0,7455	0,7027	0,7085	0,7444	0,7453	0,7450	0,7447	0,7455
	5	0,7610	0,7256	0,7414	0,7589	0,7597	0,7603	0,7598	0,7593
Görüntü 7	2	0,6975	0,6949	0,6865	0,6975	0,6975	0,6975	0,6975	0,6975
	3	0,7112	0,7032	0,6869	0,7112	0,7106	0,7111	0,7112	0,7112
	4	0,7084	0,7029	0,7216	0,7217	0,7218	0,7216	0,7214	0,7217
	5	0,7338	0,6940	0,7119	0,7315	0,7289	0,7334	0,7332	0,7350
Görüntü 8	2	0,7178	0,7137	0,7204	0,7172	0,7172	0,7172	0,7172	0,7178
	3	0,7186	0,6762	0,7155	0,7203	0,7159	0,7198	0,7203	0,7203
	4	0,7129	0,7275	0,7255	0,7255	0,7226	0,7246	0,7255	0,7255
	5	0,7294	0,7283	0,7288	0,7288	0,7239	0,7283	0,7294	0,7293
Görüntü 9	2	0,7123	0,7105	0,7108	0,7123	0,7119	0,7123	0,7123	0,7123
	3	0,7154	0,7115	0,7193	0,7144	0,7153	0,7153	0,7147	0,7153
	4	0,7449	0,7361	0,7215	0,7214	0,7205	0,7215	0,7212	0,7215
	5	0,7285	0,7240	0,7139	0,7281	0,7281	0,7285	0,7278	0,7279
Görüntü 10	2	0,7354	0,7121	0,7598	0,7268	0,7269	0,7125	0,7269	0,7268
	3	0,7536	0,7115	0,7386	0,7463	0,7463	0,7463	0,7435	0,7463
	4	0,8102	0,7674	0,7536	0,7451	0,7302	0,7536	0,7574	0,7485
	5	0,7723	0,7669	0,7735	0,7720	0,7338	0,7663	0,7532	0,7663

Tablo 4.37. Ortalama PSNR deęerleri

Test Görüntüsü	nTh	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
Görüntü 1	2	14,0204	10,7312	10,1710	10,7312	10,3919	10,7312	10,7312	10,7312
	3	15,4191	13,2447	13,9163	13,2447	13,1516	13,2447	13,3381	13,2447
	4	15,0235	13,6785	15,9447	13,7822	13,5794	13,7907	13,6785	12,9248
	5	15,3961	17,0728	13,8291	14,0632	12,0926	14,6875	13,8271	13,9528
Görüntü 2	2	13,1088	8,7163	12,5948	12,4469	8,7163	12,4469	12,4469	12,4469
	3	20,6931	14,1940	19,7124	14,1957	14,8580	14,1967	14,1940	14,1940
	4	18,3574	16,6771	20,4183	15,6782	12,2015	16,4712	16,4712	13,4717
	5	22,0453	20,5861	16,3204	15,3399	10,4179	16,1155	16,7431	15,5273
Görüntü 3	2	15,2375	15,0386	13,7220	15,0386	13,0353	14,9759	15,0386	15,0386
	3	13,9926	19,2385	10,2507	19,2389	16,5466	19,2139	19,2384	16,7512
	4	18,7880	20,0247	8,0390	20,0115	16,5884	21,3932	20,9133	19,7180
	5	23,8915	20,4459	22,0435	21,3776	17,7390	22,0435	21,3925	20,1416
Görüntü 4	2	10,4051	8,8176	11,0498	8,8176	10,0307	9,2095	8,8176	7,8615
	3	15,6960	10,5661	13,1799	10,6619	9,6582	10,6619	10,6619	10,6619
	4	14,5063	10,8206	16,6157	10,4321	9,3507	10,8206	10,8206	10,5285
	5	19,2812	19,1116	10,5528	10,7471	11,4699	10,5499	9,8970	10,3695
Görüntü 5	2	12,4688	10,6291	9,5888	10,6291	11,4505	10,7330	10,6291	10,6291
	3	9,6490	16,5229	15,0733	16,4904	16,3352	16,5229	16,5229	16,5229
	4	17,4187	16,5955	13,5351	15,2231	14,0129	15,5591	16,5962	15,3934
	5	18,2747	18,6564	15,9758	15,2558	15,4428	15,9710	16,1473	15,2733
Görüntü 6	2	11,2975	10,8821	10,0799	10,8821	10,8821	10,8821	10,8821	10,8821
	3	13,5471	13,4035	14,9966	13,4035	12,6151	13,4035	13,4035	13,4035
	4	15,8567	13,7892	13,6969	13,7829	14,6616	13,7892	13,7933	14,2841
	5	16,4859	17,9054	14,0293	14,0223	14,0273	14,1594	13,9016	13,9035
Görüntü 7	2	12,0777	9,2195	13,9620	9,2195	9,2195	9,2195	9,2195	9,2195
	3	15,4404	11,5266	16,7819	11,5266	11,1048	11,5282	11,5266	11,5266
	4	18,5956	12,2068	16,9321	12,0886	12,2071	12,2068	11,7458	12,0886
	5	19,4828	19,1316	12,0277	11,1292	10,0258	11,9103	11,7943	12,5118
Görüntü 8	2	16,5345	12,2607	17,2722	12,2607	12,2607	12,2607	12,9369	12,9369
	3	17,4534	16,4543	11,8762	17,9911	13,4576	17,9860	17,9911	17,9911
	4	17,3710	18,4014	15,6717	18,4001	15,3465	18,3824	18,4014	18,4014
	5	19,3693	22,9668	18,4769	18,4724	17,4796	18,4655	18,4779	18,4752
Görüntü 9	2	13,0235	11,1657	10,7426	11,1657	9,8760	11,1657	11,1657	11,1657
	3	16,8327	13,9854	17,7054	13,7233	12,2324	13,9854	13,7206	13,9854
	4	19,0988	14,9549	17,5957	14,8010	12,0856	14,9549	14,6498	14,9549
	5	14,5579	14,0562	14,8996	14,4277	14,5823	14,8996	14,1255	14,5814
Görüntü 10	2	16,1799	14,9669	11,6502	14,9644	14,9669	16,0845	14,9644	14,9644
	3	16,1297	19,4953	7,4963	19,4953	19,9517	19,4953	19,4953	19,4953
	4	21,1894	20,5022	13,2727	19,9723	18,1939	20,5023	20,2770	20,2770
	5	21,7917	15,8427	20,9791	21,2171	17,8390	21,2253	20,9793	20,9793

Şekil 4.27, tüm cilt kanseri görüntüleri için ortalama PSNR değerlerini temsil etmektedir. Değerler, 30 bağımsız çalıştırma ile tüm görüntüler için PSNR değerlerinin ortalaması alınarak elde edilmiştir.




Şekil 4.25. Tüm deri kanseri görüntüleri için elde edilen ortalama SSIM değerleri



Şekil 4.26. Tüm deri kanseri görüntüleri için elde edilen ortalama FSIM değerleri

Ortalama PSNR değerlerinin en iyisi, önerilen yöntemle 2.seviyede 13.4354 ile, 3.seviyede 15.4853 ile, 4.seviyede 17.6305 ile ve 5.seviyede 19.0576 ile elde edilmiştir. PSNR değerlerinin ikinci en

iyi ortalama deęerleri AOA tarafından 2.seviyede 12.0833 ile, WOA tarafından 3.seviyede ve 4.seviyede; 15.0239 ve 15.7870 ile ve PSO tarafından 5.seviyede 18.5776 ile elde edilmiřtir.




řekil 4.27. Tm deri kanseri grntleri iin elde edilen ortalama PSNR deęerleri

Test fonksiyonları zerinden elde edilen deneysel sonular, PS-VTS optimizasyon ynteminin, test fonksiyonlarının oęunda orijinal PSO'dan ve dięer son teknoloji yntemlerden daha iyi performans gsterdięini doęrulamıřtır. Bununla birlikte, bltlemenin deneysel sonuları da nerilen yntemin SSIM, FSIM ve PSNR indeksleri aısından dięer algoritmalarından daha iyi performans gsterdięini gstermektedir.

Gelecek alıřmalarda, PSO iin nerilen ziyaret tablosu stratejisi dięer metasezgisel algoritmalarla da uygulanarak benzer algoritmaların geliřimine katkı sunabilir. nerilen PS-VTS yntemi, grnt iřleme, sınıflandırma vb. birok uygulamaya hitap etmektedir. nerilen yntem, daha doęru zmler elde etmek iin farklı grnt veri kmelerine geniřletilebilir. Ziyaret tablosu stratejisi dięer metasezgisel yntemlerle test edilmelidir. Gelecekteki perspektiflerde, nerilen PS-VTS optimizasyonu, eřitli gerek dnya problemlerini zmek iin uygulanabilir. Gelecekteki alıřmalarda algoritmaları iyileřtirmek ve hesaplama sresini azaltarak daha doęru zmlere ulařmak iin ziyaret tablosu stratejisi geliřtirilebilir.


4.6. PS-VTS Yntemi ile Otomatik Duygu Sınıflandırması

Bir EEG sinyalinin ham sinyali ve alak geiren filtre sinyali řekil 4.28a'da verilmiřtir. EEG sinyali iin alfa, beta, gama, teta ve delta ritimlerinin sinyalleri de řekil 4.28(b-f)'de grlmektedir.




Şekil 4.28. EEG sinyali ve ritimleri

EEG kanal sinyalleri gürültü giderme için filtrelendikten sonra DWT yöntemi ile ritim çıkarımı gerçekleştirilmiştir. Özellik çıkarımı için önceden eğitilmiş CNN modeli kullanıldığından, CWT yöntemi her ritim sinyalini bir ritim görüntüsüne dönüştürmektedir. EEG ritim görüntüleri Şekil 4.29'da gösterilmektedir. Şekilde, x eksenı zamanı ve y eksenı frekansı temsil etmektedir.



Şekil 4.29. EEG sinyallerinin ritim görüntüleri


En verimli ritim ve kanal kombinasyonunu seçmek için iki model dikkate alınmıştır. Model 1 için akış şeması Şekil 4.30’da gösterilmiştir.



Şekil 4.30. Model 1 ile optimum kanal ve ritim seçiminin akış şeması

İlk modelde (Model 1) tüm kanalların beş ritminden en iyi ritimler belirlenir. Öncelikle her kanal için tek bir ritim seçilir. Ardından, her kanalın seçilen en iyi ritimleri, en iyi kanal-ritim kombinasyonunu belirlemek için optimizasyon algoritmasına girdi olarak verilir.

Model 2 için optimum kanal ve ritim seçimine ilişkin akış şeması Şekil 4.31’de verilmiştir. Bu modelde, optimizasyon algoritması ile her ritim için en uygun kanallar seçilir. Ardından seçilen kanalların her bir ritim için seçilen kanallar ile elde edilen doğruluk değerleri karşılaştırılarak ilgili ritim ile en verimli (optimum) kanal seti belirlenir.



Şekil 4.31. Model 2 ile optimum kanal ve ritim seçiminin akış şeması

Deneyler, Windows 10 ortamında, Intel core-i7 (9. Nesil) işlemci ve 16 GB RAM ile MATLAB 2020a kullanılarak gerçekleştirilmiştir. Çapraz geçerlilikte, eğitim için verilerin %75'i ve test için %25'i kullanılmıştır. Sınıflandırma işlemi on kez gerçekleştirilmiştir ve veri setinin rastgele bölünmesiyle ortaya çıkan öngörülemezliği azaltmak için ortalama sınıflandırma doğruluğu hesaplanmıştır. Çeşitli örüntü sınıflandırma uygulamalarında SVM algoritması iyi performans gösterdiği için tercih edilmiştir [25]. SVM algoritması, tahmin hatasının en aza indirildiği maksimum marjlı hiperdüzlemi bulmayı amaçlamaktadır. SVM algoritmasının C parametresi $[10^{-4}-10^3]$ aralığında optimize edilmiştir. Radyal tabanlı çekirdek fonksiyonu (radial basis kernel function) dikkate alınmıştır ve gama parametresi ızgara arama optimizasyon algoritması kullanılarak ayarlanmıştır.

SVM tabanlı PS-VTS algoritması, en verimli ritim ve kanal kombinasyonunu seçen bir optimizasyon mekanizması olarak kullanılmıştır. PS-VTS parametreleri ve açıklamaları Tablo 4.38’de verilmiştir.

Tablo 4.38. PS-VTS algoritmasında kullanılan parametreler ve değerleri.

Parametre	Tanım	Değer
C ₁ , C ₂	Hızlandırma faktörleri	1.2, 2
W	Atalet faktörü	0.9
iter	Maksimum iterasyon	1000
D	Problem boyutu	15
N	Parçacık sayısı	20
Nch	Kanal sayısı	56
Nrhythm	Ritim sayısı	5
TI	Hedef index	

Tablo 4.38’de görüldüğü gibi, PS-VTS algoritmasının standart parametrelerinden biri olan hızlandırma faktörü (1.2, 2) olarak ayarlanmıştır. Bir diğer parametresi olan atalet faktörleri ise 0.9 olarak uygulanmıştır. EEG sinyalleri için Nch ve Nrhythm parametreleri sırasıyla 56 ve 5 olarak alınmıştır. Parçacık sayısı, her algoritma için 30 çalıştırma ile 20 olarak belirlenmiştir. Maksimum iterasyon sayısı 1000 olarak alınmıştır. TI parametresi, ziyaret tablosunda hedef gıda indeksini temsil eder ve bu değer her iterasyonda güncellenmektedir.

Bu çalışmada DEAP veri seti kullanılmıştır. Bu veri setine otuz iki kişi (%50 kadın) katılmış ve her kişiye 40 video izletilmiştir. Burada her deneme 1 dakikaya karşılık gelmektedir. Bu nedenle her bir kişi için 40 dakikalık bir müzik videosu oynatılmıştır. Ortaya çıkan EEG sinyalleri, 512 Hz’lik bir örnekleme frekansı ile kaydedilmiştir ve 128 Hz’lik bir örnekleme frekansı ile aşağı-örnekleştir. Duyguların etiketlenmesi sırasında çift etiketleme dikkate alınmıştır. Değerlik değerlendirmeleri 0 ile 5 arasında ölçeklendirilmiştir, 0 nötr duyguları ve 5 olumlu duyguları temsil etmektedir. Beşin üzerindeki diğer derecelendirme ölçekleri aktif olarak görülürken, beşin altındaki uyarılma seviyeleri pasif olarak kabul edilmiştir. Sonuç olarak, sınıf adları sırasıyla, düşük değerlikli (LV) yüksek uyarılmış (HA) ve düşük uyarılmış (LA) yüksek değerlikli (HV)’dir.

Model 1 için HV (yüksek değerlik)-LV (düşük değerlik) ve HA (yüksek uyarılma)-LA (düşük uyarılma) sınıflandırmalarının doğruluk puanları Tablo 4.39’da verilmiştir. Model 1 ile HV-LV sınıflandırması için en uygun kanallar Alfa ritminde Cz, PO3, F3, C3, FC1 ve Fz olarak %97.1429 doğruluk oranı ile bulunmuştur. Bununla birlikte, PSO yöntemi kullanılarak %96.0714 doğruluk oranı ile en uygun kanal setinin Cz, PO3, F3, C3, Oz, Pz ve Fz olduğu bulunmuştur. Görüldüğü gibi önerilen PS-VTS yöntemi Alfa ritmi ile daha az kanal kullanarak daha iyi sonuçlar vermiştir. Sekiz kanalla (Fc1, C3, P3, P7, Fp2, F8, Fc2 ve P4) beta ritmi için %97.8571 doğruluk puanı elde edilmiştir. Her iki yöntemde de P4, FC5, AF3 ve P3 kanallarında, delta ritminde %93,9286 ile aynı doğruluk puanı elde edilmiştir. Önerilen yöntem ile P7, FC5, Fz ve Cz kanallarını kullanarak gama ritminde %91.7857 doğruluk puanı elde edilmiştir. PSO yönteminde, P7, C3, FC5, Fz, Fp1 ve Cz’nin optimum kanal seti ile doğruluk puanı %88.9286 olarak bulunmuştur. Önerilen yöntemin gama ritmi üzerinde daha az kanal ile daha iyi sonuçlar verdiği gözlemlenmiştir. Son olarak HV-LV sınıflandırması için Teta ritminde, önerilen yöntem ile Fc1,

F3, Cz, PO3, O2, CP6, C3 olarak elde edilen optimum kanal setinde %96.4286 doğruluk puanı elde edildiği görülmüştür. Ancak PSO yönteminde optimum kanal seti ile %93.5714 gibi daha düşük bir doğruluk puanının bulunduğu görülmüştür.

Tablo 4.39. Model 1 için HV-LV ve HA-LA sınıflandırmasında seçilen optimum kanallar ve doğruluk değerleri

Ritim	HV ve LV sınıflandırma				HA ve LA sınıflandırma			
	PS-VTS		PSO		PS-VTS		PSO	
	Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)
Alfa	6	97.1429	7	96.0714	5	96.7857	5	96.7857
Beta	8	97.8571	8	97.8571	5	99.2857	6	98.9286
Delta	4	93.9286	4	93.9286	3	98.9286	3	98.9286
Gama	4	91.7857	6	88.9286	5	98.2143	7	96.7857
Teta	7	96.4286	4	93.5714	6	97.1429	10	95.7143

HV-LV ve HA-LA sınıflandırması için Model 2 ile seçilen optimum kanalların doğruluk puanları ve sayıları Tablo 4.40'da sunulmuştur. Model 2 ile HA-LA sınıflandırması için, optimum olarak seçilen Fp2, PO3, F7, C3 ve F3 kanalları aracılığıyla alfa ritminde PS-VTS ve PSO yöntemleri kullanılarak %96.7857 ile aynı doğruluk elde edilmiştir. Beta ritminde PS-VTS yöntemiyle belirlenen en uygun kanal kümesi, %99.2857 doğrulukla P7, FC5, Fc1, F8 ve Fp2 şeklinde olmuştur.

Bununla birlikte, PSO yöntemi, O2, FC5, Fc1, F8, CP1 ve Fp2 olarak seçilen optimum kanallar aracılığıyla %98,9286'lık bir doğruluk elde etmiştir. Önerilen yöntemin beta ritminde daha az kanalla daha iyi puan aldığı görülmektedir. Delta ritminde, her iki yöntem de F3, Cz ve F7'nin optimum kanallarıyla aynı doğruluk puanı olan 98.9286'ya sahip olmuşlardır. PS-VTS yöntemi, optimum Fc1, P7, F7, P8 ve Pz kanallarıyla Gama ritminde %98.2143 doğruluk elde etmiştir (Tablo 4.41). Önerilen yöntem ayrıca P7, CP5, Oz, C4, FC2 ve FC6 olarak seçilen daha az optimum kanal ile teta ritmi için daha iyi sonuçlar vermiştir.

HV-LV sınıflandırmasında PS-VTS yöntemi için %97,8571 doğrulukla optimum kanallar ve ritim seti {(Fp1, 2), (F3, 2), (T3, 5), (CP1, 1), (P3, 3), (P7, 1), (PO3, 1), (O1, 2) ve (Oz, 3)} olarak bulunmuştur. Bununla birlikte, PSO yöntemi için {(6, 2), (3, 5), (13, 1), (24, 1), (10, 5), (10, 5), ve (15, 1)} en uygun kanal-ritim kombinasyonları ile %97.1298' lik bir doğruluk elde etmiştir. HA-LA sınıflandırması için optimum kanallar ve ritimler {(17, 1), (3, 3), (15, 3), (8, 4), (24, 3), (4, 3), (6, 3), (12, 1), (7, 3), and (9, 1)} şeklinde PS-VTS yöntemini kullanarak %99,2871 doğrulukla bulunmuştur.

Tablo 4.40. Model 2 için HV-LV ve HA-LA sınıflandırmasında seçilen optimum kanallar ve doğruluk değerleri

HV ve LV sınıflandırma				HA ve LA sınıflandırma			
PS-VTS		PSO		PS-VTS		PSO	
Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)	Kanal No	Doğruluk (%)
6	97.8571	9	97.1298	10	99.2871	12	98.9286

Bununla birlikte, PSO ile %98,9286 doğruluk puanı elde edilir ve bulunan optimum kanal-ritim seti {(17, 1), (5, 3), (3, 3), (15, 3), (8, 4), (24, 3), (4, 3), (6, 3), (12, 1), (13, 3), (7, 3) ve (9, 1)} şeklindedir. Önerilen yöntemin her iki sınıflandırmada da PS-VTS algoritması ile daha az kanalla daha iyi sonuçlar verdiği görülmektedir. Model 1 ve Model 2 için PSO ve PS-VTS tarafından seçilmiş optimum kanallar sırasıyla Tablo 4.41 ve Tablo 4.42’de sunulmuştur. Alfa, beta, gama, delta ve teta ritimleri için Model 1 ile HV-LV ve HA-LA sınıflandırmalarındaki doğruluk skorunun karşılaştırmalı sonuçları sırasıyla Şekil 4.32 ve Şekil 4.33’de gösterilmektedir.


Tablo 4.41. Model 1 için önerilen PS-VTS ve orijinal PSO ile seçilen optimum kanallar.

Rhythm	HV ve LV sınıflandırma		HA ve LA sınıflandırma	
	PS-VTS	PSO	PS-VTS	PSO
Alfa	Cz, PO3, F3, C3, FC1, Fz	Cz, PO3, F3, C3, Oz, Pz, Fz	Fp2, PO3, F7, C3, F3	Fp2, PO3, F7, C3, F3
Beta	Fc1, C3, P3, P7, Fp2, F8, Fc2, P4	Fc1, C3, P3, P7, Fp2, F8, Fc2, P4	P7, FC5, Fc1, F8, Fp2	O2, FC5, Fc1, F8, CP1, Fp2
Delta	P4, FC5, AF3, P3	P4, FC5, AF3, P3	F3, Cz, F7	F3, Cz, F7
Gama	P7, FC5, Fz, Cz	P7, C3, FC5, Fz, Fp1, Cz	Fc1, P7, F7, P8, Pz	T3, Fc1, P7, F7, C4, P8, Pz
Teta	Fc1, F3, Cz, PO3, O2, CP6, C3	F3, Cz, PO3, CP6	P7, CP5, Oz, C4, FC2, FC6	P7, CP5, Oz, FC5, Fz, Cz, T3, F7, FC2, FC6


Tablo 4.42. Model 2 için önerilen PS-VTS ve orijinal PSO ile seçilen optimum kanallar.

	HV ve LV sınıflandırma		HA ve LA sınıflandırma	
	PS-VTS	PSO	PS-VTS	PSO
Kanallar	Fp1, F3, T3, CP1,	FC1, F3, PO3, Cz, CP1, Oz	Fp2, F3, Oz, T3, Cz,	Fp2, FC5, F3, Oz, T3,
	P3, P7, PO3, O1, Oz		F7, FC1, P7, C3, CP5	Cz, F7, FC1, P7, PO3, C3, CP5
Ritimler	2,2,5,1,3,1,1,2,3	2,5,1,1,5,1	1,3,3,4,3,3,3,1,3,1	1,3,3,3,4,3,3,3,1,3,3,1

Şekil 4.32’de mavi ve turuncu noktalar, sırasıyla PSO ve PS-VTS yöntemleri kullanılarak Model 1 için optimum kanal ve ritim setleri ile HV-LV sınıflandırmasında elde edilen doğruluk puanlarını temsil etmektedir. PS-VTS yönteminin alfa, teta ve gama ritimlerinde daha yüksek doğruluğa ulaştığı görülmektedir. Bununla birlikte, beta ve delta ritimlerinde PS-VTS ve PSO yöntemleri ile rekabetçi sonuçlar elde edilmiştir.




Şekil 4.32. Model 1 için HV-LV sınıflandırmasında seçilen kanallar ile elde edilen doğruluk puanları



Şekil 4.33. Model 1 için HA-LA sınıflandırmasında seçilen kanallar ile elde edilen doğruluk puanları

Şekil 4.33'den görülebileceği gibi, en verimli optimum kanallar, PS-VTS yöntemi ile beta, delta ve gama ritimleri üzerinde elde edilmektedir. Bununla birlikte, PSO ve PS-VTS yöntemleri ile alfa ve delta ritimleri kullanılarak rekabetçi sonuçlar elde edilmektedir. İki modele hem PS-VTS hem de PSO algoritmaları uygulanmıştır. Model 1 ve Model 2 ile elde edilen doğruluk puanları, PSO ve PS-VTS yöntemleriyle karşılaştırmalı olarak Şekil 4.34'de verilmiştir. Şekilde, x eksenini HV-LV ve HA-LA sınıflandırmalarını, Y eksenini ise doğruluk değerlerini belirtmektedir.

Şekil 4.34'den PS-VTS yönteminin her iki sınıflandırma için de en iyi sonuçları verdiği söylenebilir. Ayrıca her iki algoritmada da Model 2 için seçilen optimum kanal ritim setleriyle daha yüksek doğruluk puanları elde edildiği görülmektedir. Önerilen modeller kullanılarak HV-LV ve HA-LA sınıflandırması için optimum kanal-ritim seçim sürecinde elde edilen hesaplama süreleri Tablo 4.43'de verilmiştir. Model 1 için elde edilen hesaplama süreleri HV-LV ve HA-LA sınıflandırmalarında alfa, beta, teta, gama ve delta ritimleri için yine bu tabloda sunulmuştur.



Şekil 4.34. PSO ve PS-VTS ile Model 1 & Model 2 için doğruluk puanlarının karşılaştırılması

Tüm ritimlerin sınıflandırmayı yaklaşık olarak aynı sürede tamamladığı görülmektedir. Ek olarak, Model 2 kullanılarak HV-LV ve HA-LA sınıflandırması için hesaplama süreleri de bu tabloda verilmiştir. Model 2'nin optimum kanal-ritim seçimini daha kısa bir sürede gerçekleştirdiği görülmektedir.

Sonuçlardan, EEG sinyallerinde Beta ritminin hem HV-LV hem de HA-LA ayrımı için diğer ritimlerden daha iyi performans gösterdiği not edilebilir. Fc1, C3, P3, P7, Fp2, F8, Fc2 ve P4 kanalları, HV-LV sınıflandırması için yüksek doğruluk puanları vermiştir. P7, FC5, Fc1, F8 ve Fp2 kanalları, HA-LA sınıflandırması için en iyi doğruluğu üretmiştir.

Tablo 4.43. Optimum kanal-ritim seçim sürecinin hesaplama süreleri

Ritim	Model 1		Model 2	
	HV-LV sınıflandırma	HA-LA sınıflandırma	HV-LV sınıflandırma	HA-LA sınıflandırma
Alfa	2.06e+05	2.54e+06		
Beta	1.98e+05	2.50e+05		
Teta	2.18e+05	2.56e+05		
Gama	2.12e+05	2.60e+05	2.72e+05	3.08e+05
Delta	2.19e+05	4.23e+05		
Toplam	1.05e+06	3.73e+06		

Sonuçlarımız, Model 2'nin her kanaldaki en iyi ritimleri belirledikten sonra en uygun kanal setini seçmede daha doğru olduğunu göstermektedir. Tablo 4.44, modelimizin aynı veri seti kullanılarak geliştirilen diğer son teknoloji modellerle karşılaştırmasını özetlemektedir.

Tablo 4.44. Geliştirilen yöntemin aynı veri seti kullanılarak geliştirilen diğer son teknoloji modellerle karşılaştırılması.

Çalışma	HV-LV sınıflandırma (%)	HA-LA sınıflandırma (%)
Gupta ve ark. [165]	67.00	69.00
Zhuang ve ark. [166]	70.41	72.10
Arnau-González ve ark. [167]	69.60	67.70
Yang ve ark. [168]	90.80	91.03
Xing ve ark. [74]	81.10	74.38
Cheng ve ark. [74]	97.69	97.53
Sarma ve ark. [169]	82.21	86.00
Li ve ark. [170]	64.22	65.70
He ve ark. [171]	64.33	63.23
Li ve ark. [172]	71.29	71.92
Yan ve ark. [173]	82.75	84.22
Li ve ark. [174]	97.41	97.25
Li ve ark. [175]	89.96	90.01
Demir ve ark. [69]	91.1	98.9
Proposed Method	97.85	99.28

Tablo 4.44'de önerilen yaklaşımın HV-LV sınıflandırması için %97.85'lik doğruluk puanı ile en iyi doğruluğu ürettiği görülmektedir. Sadece Li ve arkadaşları [174] ve Cheng ve arkadaşları [176] sırasıyla %97.41 ve %97.69 doğruluk puanı ile bizim çalışmamıza yakın bir doğruluk elde etmişlerdir. Ayrıca Li ve arkadaşları [174], Yan ve arkadaşları [173], Sarma ve arkadaşları [169] ve Xing ve arkadaşları [74] tarafından önerilen yaklaşımlar ile HV-LV sınıflandırması için %80'in üzerinde doğruluk skorları elde edilmiştir.

Tablo 4.44'deki diğer yöntemler, önerdiğimiz yöntemden daha düşük doğruluk puanları elde etmişlerdir. Verilen tabloda görüldüğü üzere, HA-LA sınıflandırmasında %99.28 gibi yüksek bir sınıflandırma doğruluğu geliştirdiğimiz yöntemle elde edilmiştir. Ayrıca, Li ve diğerleri [175], Li

ve diğlerleri [174], Cheng ve diğlerleri [176] ve Yang ve diğlerleri [168] tarafından önerilen yaklaşımlar ile HA-LA sınıflandırmasında %90'ın üzerinde doğruluk puanları üretilmiştir. Sarma ve arkadaşları [169] tarafından %86.00'lık bir doğruluk elde etmişlerdir. Yaklaşımların geri kalanı HA-LA sınıflandırması için %80'den daha az doğruluk puanları elde ettikleri tabloda görölmektedir.



5. SONUÇLAR

Bu çalışmada metasezgisel algoritmaların görüntü bölütleme ve sınıflandırma alanlarındaki uygulamaları gerçekleştirilmiştir. Bu kapsamda; belirtilen alanlarda kullanılan yöntemlerin, metasezgisel algoritmaların, görüntü işleme ve sınıflandırmada kullanılan yapılarının ve modellerin başarımlarının artırılmasına yönelik sayısız çalışmalar ve analizler yapılmıştır. Yapılan çalışmalar altı başlık altında toplanmıştır. Bu çalışmaların daha iyi anlaşılabilmesi ve değerlendirilmesi amacıyla geliştirilen yöntemler ve kapsamaları Tablo 5.1’de özetlenmektedir. Bu tabloda çalışmalarda kullanılan yöntemler, bu yöntemlerin uygulandığı veri setleri ve problemler, çalışmaların özgün değerleri ve başarımları özetlenmektedir.

İlk çalışmamızda, görüntü eşikleme hesaplama süresini azaltmak ve eşikleme performansını iyileştirmek amacıyla güçlü ve güncel optimizasyon algoritmalarında biri olan GoldSa II optimizasyonuna, iki boyutlu yerel olmayan ortalamalar histogramına ve Renyi'nin entropisine dayalı yeni bir eşikleme yöntemi (NLM-GoldSa-II) geliştirilmiştir. GoldSa II azalan sinüs fonksiyonu ve altın oranı kullanarak arama alanını daraltan ve böylece hedeflenen optimum noktayı (optimum eşikler) daha kısa sürede daha doğru bir şekilde yakınsayan güçlü bir yöntem olması sebebiyle tercih edilmiştir. Önerilen NLM-GoldSa II bölütleme yönteminin performans değerlendirmeleri BDE, GCE, PRI, VOI, SSIM, FSIM, PSNR, MSE, CC, AD, MD ve NAE olmak üzere 12 farklı görüntü kalitesi ölçüm indeksleri kullanılarak gerçekleştirilmiştir. Deneysel çalışmalar, BSDS300 veri setindeki 300 görüntü üzerinde gerçekleştirilmiştir. Önerilen yöntem ile görüntülere 3-seviyeli ve 5-seviyeli eşikleme gerçekleştirilmiş olup GSA, ABC, DE, cKGSA, eKGSA ve PSO yöntemleri ile karşılaştırılarak sonuçlar sunulmuştur. Elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ 3-seviyeli ve 5-seviyeli eşiklemeler için önerilen yöntem en iyi değerlerin elde edilmesinde 12 değerlendirme indeksinden 7’sinde birinci sırada, 3’ünde ikinci sırada yer almaktadır.
- ✓ GoldSa-II’den sonra en iyi değerlerin elde edilmesinde başarımlı yüksek olan yöntem PSO olmuştur. PSO yöntemi, 3-seviyeli eşiklemede 12 değerlendirme indeksinden 4’ünde, 5-seviyeli eşiklemede 2’sinde birinci sırada yer almaktadır.
- ✓ Bununla birlikte, önerilen yöntem ile 3 seviyeli eşikleme için MD' de %5.4151, CC' de %33.11, RMSE' de %0.1011, FSIM' de %0.1618, VOI' de %0.6180, BDE' de %0.0615 ve PRI' da %0.4557 oranında iyileşme sağlanmıştır.
- ✓ 5 seviyeli eşikleme için NAE' de %1.3591, MD' de %3.2552, CC' de %17.6973, RMSE' de %0.2176, SSIM' de %0.1939, FSIM' de %0.02551 ve BDE' de %1.7236 oranında iyileşme sağlanmıştır.
- ✓ İndekslerde en iyi olarak belirlenen üç yöntem (GoldSa-II, PSO ve eKGSA) hesaplama süreleri açısından incelenmiştir. Veri setinden rastgele alınan sekiz görüntü için hesaplama

periyotlarının hem 3-seviyeli eşik hem de 5-seviyeli eşiklemeler için seçilen yöntemlerde yaklaşık olarak aynı olduğu gözlenmiştir.

İkinci çalışmamızda, GoldSa yönteminin dezavantajlarını gidererek çok daha geniş çeşitlilikteki problemler üzerindeki etkililiğini artırmak amacıyla kaotik haritalarla zenginleştirilmiş karşıtlık tabanlı bir Altın Sinüs Algoritması (CoGoldSa) önerilmiştir. Bu yaklaşım iki aşamada gerçekleştirilmiştir: İlk aşamada, GoldSa parametrelerinin kaotik davranışları analiz edilmiştir. Kaotik haritaların farklı davranışa sahip parametreler üzerindeki etkisini belirlemek ve literatürde en çok kullanılan sekiz kaotik haritanın GoldSa yöntemi üzerindeki etkisini gözlemlemek amaçlanmıştır. Bu amaçla, GoldSa'nın farklı davranışlara sahip üç parametresi için sekiz kaotik harita ile üç algoritma geliştirilerek performansları analiz edilmiştir. İkinci aşamada, optimizasyon algoritmalarında başlangıç noktasının doğru yerden başlaması yöntemin başarımında ve işlem süresinin kısaltılmasında oldukça etkin olduğundan karşıtlık temelli öğrenme stratejisi cGoldSa'ya ilave edilmiştir. Önerilen yöntemin etkililiğini araştırmak için, 50 kıyaslama fonksiyonları ve dört klasik mühendislik tasarım problemleri üzerinde iyi bilinen ve yeni tanıtılan meta-sezgisel yaklaşımlarla, bunlar; MVO, MFO, WOA, AOA, AO, CO, RSA, GMO, and SAO, analizler yapılmıştır. Ayrıca, göğüs kanserinin patolojik görüntülerin verimli bir şekilde işlenmesinin tıbbi teşhiste oldukça önemli olması nedeniyle, Co-GoldSa yöntemine dayalı olarak etkili bir görüntü bölütleme şeması sunulmuştur. Deneysel sonuçlar, önerilen yöntemin küresel optimizasyon problemleri, görüntü bölütleme ve mühendislik problemlerinin çözümü üzerindeki üstünlüğünü ortaya koymaktadır. Bu çalışmadan elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ Bir dizi istatistiksel testten (ortalama, en iyi, en kötü ve standart sapma) elde edilen sonuçlar ışığında, daire kaotik haritası ile zenginleştirilmiş GoldSa 2'nin, sekiz kaotik harita ile oluşturulan üç GoldSa algoritması arasında en etkili yaklaşım olduğu belirlenmiştir.
- ✓ Geliştirilmiş karşıtlık tabanlı cGoldSa yöntemi, kıyaslama fonksiyonları üzerinde yapılan deneylerde cGoldSa ve standart GoldSa yöntemine göre daha doğru sonuçlar elde etmiştir. Karşıtlık temelli öğrenme stratejisinin başlangıç popülasyonunun ve algoritmanın geliştirilmesinde oldukça etkili olduğu sonucuna varılabilir.
- ✓ Co-GoldSa yöntemi diğer dokuz meta-sezgisel ile karşılaştırıldığında, çekme/basma yayı tasarım probleminde; $1.268e-2$ ortalama değeri, kaynaklı kirli tasarım probleminde; 1.7276 ortalama değeri, basınçlı kap tasarımında; $3.059e+3$ ortalama değeri ve üç çubuklu kafes tasarım probleminde; $2.63e+2$ ortalama değeri ile en iyi sonuçlara sahiptir.
- ✓ MTIS uygulamalarında önerilen yöntem, 0.9150 ortalama SSIM değeri, 0.9445 ortalama FSIM değeri ve ortalama 23.6380 ortalama PSNR değeri ile tüm görüntülerin tüm eşik seviyelerinde diğer metasezgisel yöntemlere göre üstün sonuçlar üretmiştir.

- ✓ Önerilen yöntemin çeşitli alanlardaki optimizasyon problemlerinde başarılı sonuçlar ürettiği kanıtlanmıştır.
- ✓ Ayrıca, bu çalışma yeni tanıtılan meta-sezgisel yaklaşımların çok seviyeli eşikleme görüntü bölütleme alanında ve klasik mühendislik problemleri üzerinde iyi bilinen tekniklerle karşılaştırmalı olarak ayrıntılı bir analizini içermektedir.

Üçüncü çalışmamızda, metafor tabanlı algoritmalar yerine basit bir optimizasyon tekniği kullanarak eşikleme problemini basitleştiren çok seviyeli bir görüntü eşikleme yaklaşımı geliştirilmiştir. Bu kapsamda, bölütlenecek bölge sayısını otomatik bulan, kaotik haritalarla zenginleştirilmiş Rao (Chaotically Enhanced Rao-CER) algoritması bu çalışmada sunulmuştur. Çok seviyeli görüntü eşiklemede Rao algoritmasını iyileştirmek için Logistic, Sine, Sinusoidal, Gauss, Circle, Chebyshev, Singer ve Tent olmak üzere sekiz farklı kaotik haritalama yaklaşımı kullanılmıştır. Önerilen yöntemin etkinliği 300 görüntü içeren BSDS300 veri seti üzerinde BDE, PRI, GCE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD, NAE ve MD metrikleri kullanılarak değerlendirilmiş ve elde edilen sonuçlar literatürdeki mevcut çok seviyeli eşikleme yöntemleri ile karşılaştırılmıştır. Deneysel çalışmalarda, geliştirilen CER algoritması diğer yöntemlere kıyasla üstün sonuçlar üretmiştir. BuAyrıca önerilen yöntem hız ve doğruluk açısından daha iyi yakınsama sağlamıştır. Bu çalışmadan elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ Geliştirilmiş uyarlanabilir CER algoritmasında Otsu'nun maksimum varyans yöntemine göre eşik seviyesi ile uygunluk değerinin doğru orantılı olduğu, seviye sayısı arttıkça uygunluk değerinin arttığı ancak görüntüye özgü segment sayısına gelindiğinde uygunluk değerinin aynı kaldığı veya azaldığı gözlemlenmiştir.
- ✓ Manuel olarak ayarlanması oldukça güç olan eşik seviye sayısının belirlenmesinde önerilen adaptif CER algoritması sentetik görüntüler ve gerçek görüntüler üzerinde yapılan analizlerde oldukça başarılı sonuçlar üretmiştir.
- ✓ Chebysev haritası ile geliştirilen Rao algoritması değerlendirme indekslerinin çoğunda diğer kaotik haritalar ile geliştirilen yöntemlere göre daha başarılı sonuçlar ürettiği ve optimum noktayı daha iyi yakınsadığı belirlenmiştir.
- ✓ Chebyshev ve Logistic haritalar ile zenginleştirilen adaptif Rao algoritması diğer kaotik haritalarla geliştirilenlere göre optimum noktayı daha kısa sürede yakınsamaktadır.
- ✓ Köklü ve yeni yayınlanan görüntü eşikleme teknikleri (DE, ABC, GSA, cKGSA, eKGSA) ile karşılaştırıldığında, önerilen yöntemin diğer yöntemlere göre daha etkili sonuçlar elde ettiği 12 farklı kalite ölçüm indeksi ile gösterilmiştir.
- ✓ Önerilen yöntem ile BSDS300 verisinde; 0.6572 ortalama PRI, 0.5771 ortalama SSIM, 0.7206 ortalama FSIM, 37.0342 ortalama RMSE, 17.1568 ortalama PSNR, 28.6930 ortalama AD, 0.2748 ortalama NAE değeri ile diğer karşılaştırılan köklü ve yeni yayınlanan görüntü eşikleme tekniklerine kıyasla en iyi sonuçları üretmiştir.

- ✓ Diğer metasezgisellerle yapılan hesaplama sürelerinin karşılaştırma çalışmalarından CER algoritmasının daha kısa sürede adaptif eşik seviyesini bularak optimal eşik değerlerini bulduğu belirlenmiştir.

Dördüncü çalışmamızda, basit ve kolay anlaşılabilir bir optimizasyon yöntemi olan PSO, iki boyutlu histogram ve Renyi'nin entropi yöntemi kullanılarak çok seviyeli bir görüntü eşikleme çerçevesi oluşturulmuştur. BSDS300 verisetindeki görüntülere 3 ve 5 seviye için uygulanmıştır. Algoritmanın arama yeteneği, görüntü bölütleme için Renyi'nin eşikleme yöntemi amaç fonksiyonu ile birleştirilmiştir. Yöntemin başarımı, 12 adet ölçüm indeksi (BDE, PRI, GCE, VOI, SSIM, FSIM, RMSE, PSNR, CC, AD, NAE ve MD) kullanılarak değerlendirilmiştir. Önerilen yaklaşım, farklı eşik seviyelerinde DE, ABC, GSA, KGSA, cKGSA gibi mevcut optimizasyon algoritmalarına dayalı olarak geliştirilen çok seviyeli eşikleme yöntemleriyle karşılaştırılmıştır. Bu çalışmadan elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ Deneysel çalışmalarda, önerilen yöntem 12 farklı kalite ölçüm endeksinde oldukça başarılı olan beş yöntem ile karşılaştırılmıştır ve bu yöntemlere göre daha başarılı ve etkin bir bölütleme sağlandığı deneysel sonuçlarda görülmüştür.
- ✓ 3-seviyeli bölütleme için BDE %2.63, PRI %0.83, SSIM %15.5, RMSE %13.2, PSNR %8.63, CC %35, AD %13.9, MD %14.75, NAE %10 oranında başarımlar sağlanmıştır.
- ✓ 5-seviyeli bölütlemelerde ise BDE %1, VOI %1.4, SSIM % 1.3, FSIM % 0.66, RMSE %0.46, PSNR %0.46, CC %21.69, AD %0.84 olarak başarımlar sağlanmıştır.
- ✓ Yapılan incelemelerde, karşılaştırılan en başarılı yöntem eKGSA olarak tespit edilmiştir. Hesaplama süreleri bakımından, önerilen PSO tabanlı çok seviyeli eşikleme yönteminin, eKGSA yöntemine göre daha hızlı olduğu görülmüştür.

Beşinci çalışmamızda, PSO'nun verimli ve geliştirilmiş bir versiyonu olan PS-VTS yöntemi, orijinal PSO yönteminin birkaç dezavantajını çözmek için geliştirilmiştir. Bu amaçla, sık ziyaret edilen noktalara ve komşularına daha az ziyaret yapılarak yeni noktaların keşfedilmesine olanak tanıyarak orijinal parçacık sürüsü optimizasyonu (PSO) algoritmasının gereksiz aramalarını önleyen bir ziyaret tablosu stratejisi geliştirilmiştir. Ayrıca, popülasyon çeşitliliğini artırmak ve keşif yeteneğini geliştirerek yerel optimumda sıkışıp kalmanın üstesinden gelmek için çok yönlü bir arama stratejisi tanıtılarak yöntem entegre edilmiştir. Yöntemin etkililiği, 50 kıyaslama problemi üzerinde bir takım istatistiksel testler yapılarak analiz edilmiştir. Bununla birlikte, erken cilt kanseri tespitinde oldukça önemli olan görüntü bölütleme işleminin başarılı bir şekilde gerçekleştirilmesi amacıyla önerilen PS-VTS yöntemine dayalı olarak görüntü bölütleme şeması oluşturulmuştur. Önerilen yöntemin deneysel sonuçları, literatürde en sık kullanılan metasezgisellerle (AOA, GWO, MFO, WOA, MVO, TLBO ve orijinal PSO) kıyaslanarak sunulmuştur. Bölütleme performansları, SSIM, FSIM ve PSNR görüntü kalitesi metrikleri

açısından irdelenmiştir. Bu çalışmadan elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ PSO yönteminin çok yönlü arama ve ziyaret tablosu stratejileriyle geliştirilmesiyle, kıyaslama fonksiyonlarının detaylı analizinde ve çok seviyeli segmentasyon uygulamalarında iyi bilinen meta-sezgisel yöntemlere göre önemli bir üstünlük elde edilmiştir.
- ✓ Kıyaslama fonksiyonları üzerinde gerçekleştirilen niteliksel analizde, geliştirilmiş PS-VTS yöntem ile AOA, WOA, GWO, MVO, MFO, TLBO ve PSO gibi yaygın metasezgisel yöntemlere kıyasla tek modlu ve çok modlu fonksiyonlar için en hızlı yakınsamayı elde edilmiştir.
- ✓ Benchmark fonksiyonları üzerinde yapılan kantitatif analizde, önerilen optimizasyon yöntem Uygulanan 50 test fonksiyonunun ortalama indeksine göre %60'ında, minimum indeksine göre %62'sinde, maksimum indeksine göre %42'sinde, standart sapma indeksine göre %46'sında diğer yöntemlere göre daha başarılı sonuçlar bulunmuştur.
- ✓ Önerilen yöntem, farklı boyutlarda problemlere sahip diğer algoritmalarla da karşılaştırılarak değerlendirilmiştir. Karşılaştırma fonksiyonları üzerinde gerçekleştirilen ölçeklenebilirlik analizinde önerilen yöntem, 10 boyuta ilişkin olarak 25 fonksiyonun 10'unda birinci, 5'inde ikinci sırada yer alırken, standart sapma değerlerinde ise fonksiyonların 10'unda birinci, 7'sinde ikinci sırada yer almaktadır. Önerilen yöntem, 50 boyutta 25 fonksiyonun 12'sinde birinci, 5'inde ikinci, standart sapma değerlerinde ise 12'sinde birinci, 11'inde ikinci sırada yer aldı. Son olarak, 100 boyuta ilişkin olarak geliştirilmiş PSO, sırasıyla 14 ve 7 test fonksiyonlarında en iyi ortalama ve en iyi standart sapmayı elde etti.
- ✓ Cilt kanseri görüntü segmentasyonunda, önerilen optimizasyon algoritması neredeyse tüm eşik seviyeleri ve görüntüler için diğer algoritmalarından daha iyi performans göstermektedir.
- ✓ Tüm görüntüler için değerlendirme metriklerinin ortalama değerlerine göre, cilt kanseri görüntü segmentasyonunda önerilen yöntem kullanılarak SSIM değeri 0.8285, FSIM değeri 0.7332 ve PSNR değeri 19.0576 ile en iyi sonuçlar elde edilmiştir.

Son çalışmamızda ise meta-sezgisel bir yaklaşımla tüm EEG kanalları için verimli bir ritim ve kanal kombinasyonu seçimi ile EEG tabanlı insan duygu tanıma performansını artırmak amaçlanmıştır. Bu kapsamda öncelikle, düşük geçiş filtresi kullanılarak EEG sinyallerinin gürültüsü giderilmiştir ve ayrık dalgacık dönüşümü (DWT) kullanılarak ritim çıkarımı yapılmıştır. Sürekli dalgacık dönüşümü (CWT) yaklaşımı ile her ritim sinyalini bir ritim görüntüsüne dönüştürülmüştür. Önceden eğitilmiş MobilNetv2 modeli, derin özellik çıkarımı için önceden eğitilmiş ve duyguları sınıflandırmak için SVM yöntemi kullanılmıştır. Optimum kanallar ve ritim setlerinin seçiminde için iki model geliştirilmiştir. İlk modelde her ritim için ayrı ayrı optimum kanallar seçilmekte ve ritimlerin en iyi kanal setlerine göre optimizasyon sürecinde global optimumlar belirlenmektedir. İkinci modelde, her kanal için en iyi ritimler belirlenmekte ve

ardından en uygun kanal-ritim seti seçilmektedir. Bu çalışmadan elde edilen önemli sonuçlar aşağıda maddeler halinde sunulmuştur:

- ✓ Önerilen PS-VTS algoritmasının istatistiksel analizi 15 kıyaslama fonksiyonu üzerinde minimum, maksimum, ortalama ve standart sapma endeksleri açısından incelendiğinde belirtilen endekslerde kıyaslama fonksiyonlarının çoğunda orginal PSO yöntemine göre daha iyi sonuçlar etmiştir.
- ✓ EEG sinyallerinde Beta ritminin hem HV-LV hem de HA-LA ayrımı için diğer ritimlerden daha iyi performans gösterdiği not edilebilir.
- ✓ Fc1, C3, P3, P7, Fp2, F8, Fc2 ve P4 kanalları, HV-LV sınıflandırması için yüksek doğruluk puanları vermiştir.
- ✓ P7, FC5, Fc1, F8 ve Fp2 kanalları, HA-LA sınıflandırması için en iyi doğruluğu üretmiştir.
- ✓ Sonuçlarımız, Model 2'nin her kanaldaki en iyi ritimleri belirledikten sonra en uygun kanal setini seçmede daha doğru olduğunu göstermektedir.

Önerilen yöntemin aynı veri seti kullanılarak geliştirilen diğer güncel modellerle karşılaştırılmasında, HV-LV sınıflandırmasında %97.85 ve HA-LA sınıflandırmasında %99.28 başarımla diğer yöntemlerle karşılaştırıldığında en iyi sonuçlar elde ettiği gözlemlenmiştir.

Tablo 5.1. Yapılan Çalışmalar ve Başarımları

Yöntem	Uygulama Alanı	Başarımlar
Altın Sintüs Algoritmasına Dayalı Çok Seviyeli Görüntü Eşikleme	BSDS300 veri seti	3-seviyeli ve 5-seviyeli eşiklemeler için önerilen yöntem en iyi değerlerin elde edilmesinde 12 değerlendirme indeksinden 7'sinde birinci sırada, 3'ünde ikinci sırada yer almaktadır. - Önerilen yöntem ile 3 seviyeli eşikleme için MD' de %5.4151, CC' de %33.11, RMSE' de %0.1011, FSIM' de %0.1618, VOI' de %0.6180, BDE' de %0.0615 ve PRI' da %0.4557 oranında iyileşme sağlanmıştır. 5 seviyeli eşikleme için NAE' de %1.3591, MD' de %3.2552, CC' de %17.6973, RMSE' de %0.2176, SSIM' de %0.1939, FSIM' de %0.02551 ve BDE' de %1.7236 oranında iyileşme sağlanmıştır.
Kaotik Olarak Zenginleştirilmiş Karşıtlık Öğrenme Stratejisine Dayalı GoldSa Yöntemi	50 Kıyaslama fonksiyonu - Mühendislik tasarım problemleri - BIDC veri seti	- Bir dizi istatistiksel testten (ortalama, en iyi, en kötü ve standart sapma) elde edilen sonuçlar ışığında, daire kaotik haritasıyla geliştirilmiş GoldSa 2'nin, sekiz kaotik harita ile oluşturulan üç GoldSa algoritması arasında en etkili yaklaşım olduğu belirlenmiştir. - Geliştirilen karşıtlık tabanlı cGoldSa yöntemi, kıyaslama fonksiyonları üzerinde yapılan deneylerde cGoldSa ve standart GoldSa yöntemine göre daha doğru sonuçlar elde ettiği görülmüştür. - Karşıtlık temelli öğrenme stratejisinin başlangıç popülasyonunun ve algoritmanın geliştirilmesinde oldukça etkili olduğu sonucuna varılmıştır. - Önerilen yöntem diğer dokuz meta-sezgisel ile karşılaştırıldığında çekme/basma yayı tasarım probleminde 1.268e-2 ortalama değeri, kaynaklı kiriş tasarım probleminde 1.7276 ortalama değeri, basınçlı kap tasarımında 3.059e+3 ortalama değeri ve üç çubuklu kafes tasarım probleminde 2.63 e+2 ortalama değeri ile en iyi performansı elde etmiştir. - Çok seviyeli görüntü bölütleme uygulamalarında önerilen yöntem, 0.9150 ortalama SSIM, ortalama FSIM değeri 0.9445 ve ortalama PSNR değeri 23.6380 ile tüm görüntülerin tüm eşik seviyelerinde diğer meta-sezgisel yöntemlere göre üstün sonuçlar üretmiştir.
Kaotik Olarak Zenginleştirilmiş Rao Algoritması ile Adaptif Çok Seviyeli Görüntü Eşikleme	BSDS300 veri seti	- Veri setindeki her görüntü için optimum eşik seviyesi ve değerleri adaptif olarak elde edilmiştir. Elde edilen değerlere göre görüntüler bölütlenmiştir. - Chebyshev Haritası, Rao algoritmasının geliştirilmesinde diğer yedi kaotik haritaya (logistic, sine, sinusoidal, gauss, circle, singer ve tent) kıyasla daha iyi sonuçlar ürettiği tespit edilmiştir. - Önerilen CER algoritması diğer beş yöntem (DE, ABC, GSA, cKGSA, eKGSA) göre kıyasla daha etkili sonuçlar elde ettiği 12 farklı kalite ölçüm indeksi ile gösterilmektedir. - Veri setindeki tüm görüntüler için PRI indeksinde 0.6572, SSIM indeksinde 0.5771, FISM indeksinde 0.7206, RMSE indeksinde 37.0342, PSNR indeksinde 17.1568, AD indeksinde 28.6930, NAE indeksi 0.2748 değeri ile en iyi sonuçlar önerilen yöntem ile elde edilmiştir. - Önerilen yöntem diğer yöntemlere göre optimum noktayı daha kısa sürede yakınsamaktadır.

Parçacık Sürü Optimizasyonuna Dayalı Çok Seviyeli Eşikleme	BSDS300 veri seti	- Önerilen yöntem 3 seviyeli görüntü eşiklemede BDE indeksinde 9.9713, PRI indeksinde 0.6130, SSIM indeksinde 0.5258, RMSE indeksinde 43.301, PSNR indeksinde 15.676, CC indeksinde 0.8824, AD indeksinde 36.769, MD indeksinde 94.500, NAE indeksinde 0.3670 değeri ile optimum sonuçları elde etmiştir. - Önerilen yöntem 5 seviyeli eşiklemede, BDE indeksinde 9.9713, PRI indeksinde 0.6130, SSIM indeksinde 0.5218, RMSE indeksinde 43.301, PSNR indeksinde 15.676, CC indeksinde 0.8824, AD indeksinde 36.769, MD indeksinde 94.5, NAE indeksinde 0.3670 değeri ile diğer yöntemlere göre daha iyi sonuç elde etmiştir.
Ziyaret Tablosu Stratejisine Dayalı PSO Yöntemi (PS-VTS) ile Çok seviyeli Eşikleme Yöntemi	50 kıyaslama fonksiyonu - ISIC2017 veri seti	- Kıyaslama fonksiyonları üzerinde gerçekleştirilen niteliksel analizde, geliştirilmiş PSO algoritması, AOA, WOA, GWO, MVO, MFO, TLBO ve PSO gibi yaygın metasezgisel yöntemlere kıyasla tek modlu ve çok modlu fonksiyonlar için en hızlı yakınsamayı elde etmiştir. - Benchmark fonksiyonları üzerinde yapılan kantitatif analizde, önerilen optimizasyon yöntemi uygulanan 50 test fonksiyonundan ortalama değerlere göre %60'ında ve minimum değerlere göre %62'sinde diğer yöntemlere kıyasla daha başarılı sonuçlar üretmiştir. - Karşılaştırma fonksiyonları üzerinde gerçekleştirilen ölçeklenebilirlik analizinde önerilen yöntem, 10 boyuta ilişkin olarak minimum değerlerde 25 fonksiyonun 10'unda birinci, 5'inde ikinci sırada yer alırken, standart sapma değerlerinde ise fonksiyonların 10'unda birinci, 7'sinde ikinci sırada yer almıştır. Önerilen yöntem, 50 boyut için minimum değerlerde 25 fonksiyonun 12'sinde birinci, 5'inde ikinci, standart sapma değerlerinde ise 12'sinde birinci, 11'inde ikinci sırada yer aldı. Son olarak, 100 boyutlu problemler için geliştirilmiş PSO, 25 fonksiyondan sırasıyla 14 ve 7 test fonksiyonlarında en iyi ortalama ve en iyi standart sapmayı elde etmiştir. - Cilt kanseri görüntülerinin segmentasyonunda, önerilen optimizasyon algoritması neredeyse tüm eşik seviyeleri ve görüntüler için diğer algoritmalarından daha iyi performans göstermiştir. - Tüm görüntüler için değerlendirme metriklerinin ortalama değerlerine göre, cilt kanseri görüntü segmentasyonunda önerilen yöntem kullanılarak SSIM indeksinde 0.8285, FSIM indeksinde 0.7332 ve PSNR indeksinde 19.0576 ile en iyi sonuçlar elde edilmiştir.
Ziyaret Tablosu Stratejisine Dayalı PSO Yöntemi ile EEG Sinyallerinden Duygu Sınıflandırması	DEAP veri seti	- Daha doğru EEG duygu sınıflandırması için meta-sezgisel yaklaşımın iki çeşidi tasarlanmıştır. - Duygu tanımda EEG sinyallerinin hem HV-LV hem de HA-LA ayrımları yapıldı. - EEG sınıflandırması için en uygun seçim çerçevesini araştırmak amacıyla yeni otomatik kanal ve ritim kombinasyonlarının seçim modelleri Model 1 ve Model 2 olarak tanımlanmıştır. - Model 1 için, en iyi HV-LV ayrımı için beta ritmi ile sekiz kanal seçilmiştir. HA-LA sınıflandırması için önerilen algoritma ile beta ritmi ile beş kanalın kombinasyonu optimum küme olarak seçilmiştir. - Model 2 için HV-LV sınıflandırması altı kanal ve en iyi HA-LA sınıflandırması on kanal kullanılarak elde edilmiştir. - Hem HV-LV hem de HA-LA ayrımlarında beta ritminin diğer ritimlerden daha iyi performans gösterdiği görülmüştür. - Fc1, C3, P3, P7, Fp2, F8, Fc2 ve P4 kanalları HV-LV sınıflandırması için yüksek doğruluk puanları vermiştir. P7, FC5, Fc1, F8 ve Fp2 kanalları HA-LA sınıflandırması için en iyi doğruluğu üretmiştir. - Model 2' nin daha yüksek doğrulukta sonuçlar ürettiği belirlenmiştir. - Daha az kanalla ve daha az zaman karmaşıklığıyla daha doğru duygu sınıflandırması gerçekleştirilmiştir. - DEAP veri setini kullanarak HA-LA ve HV-LV sınıflandırmaları için sırasıyla %99.2871 ve %97.8571 doğruluk elde edilmiştir.

ÖNERİLER

- Görüntü bölütleme, görüntü işlemenin ilk ve en önemli adımlarından biri olmasına ve araştırmacılar tarafından oldukça ilgi gören bir konu olmasına rağmen tasarlanan yöntemler ve bu yöntemlerin başarımları görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik arz ettiğinden sürekli geliştirilmeye ihtiyaç duyulmaktadır. Bu çalışmada, entropiye ve varyansa dayalı çeşitli bölütleme çerçeveleri önerilmiş olup enerji tabanlı eşikleme yöntemleri, bulanık entropi, köşegen sınıf entropisi gibi farklı yöntemler üzerinde çalışmalar genişletilerek görüntüler için daha optimum eşik değerleri ile daha hassas doğrulukta bölütleme sağlanabilir.
- Önerilen adaptif görüntü bölütleme yöntemi, uydu görüntüleri, tıbbi görüntüler, doğa görüntüleri, gerçek zamanlı görüntüler gibi farklı uygulama alanları için de uygulanarak daha hassas doğrulukta ve her alanda uygulanabilen otomatik bir görüntü bölütlemenin gerçekleştirilmesine yönelik çalışmalar gerçekleştirilebilir.
- Bununla birlikte gelecekteki araştırmalarda, çok seviyeli eşiklemede kullanılan çeşitli histogram yöntemleri, entropi yöntemleri veya ön filtreleme yöntemleri, çeşitli tıbbi görüntülerin hatasız bölümlendirilmesini sağlayacak şekilde geliştirilebilir. Ayrıca meta-sezgisellere yönelik yeni arama süreçleri oluşturularak yaklaşımların etkinliği artırılabilir.
- Deri üzerinde bulunan tüyler ve lekeler lezyonların görünümü etkileyebilir ve özellikle kötü huylu kanser tüyleri bu yapıların etrafında oluşabilirler. Bu da lezyonların tam olarak değerlendirilmesini ve görüntülemenin yeterliliğini zorlaştırabilir. Bu durum deri kanseri görüntülerinin bölütlenmesindeki temel zorluklardan birisidir. Lezyonlu bölgenin simetrisi bozulmadan bu yapıların kaldırılmasına yönelik çalışmalar gerçekleştirilebilir.
- Bu tez çalışması kapsamında önerilen yöntemlerden biri olan EEG kanal ve ritim seçimi yöntemleri farklı kanal sayısına sahip veri setleri için uygulanarak etkinliği ve uygulama alanları artırılabilir. Böylece yöntem daha dayanıklı hale getirilerek tıpta EEG sinyallerinden hastalık teşhisinin otomatik gerçekleştirilmesinin önünü açarak yaygınlaşmasına katkıda bulunabilir.
- Bununla birlikte, maliyet fonksiyonu olarak diğer özellik çıkarma ve sınıflandırma yöntemlerini kullanmayı araştıracağız. Yeni geliştirilen diğer meta-sezgisel yaklaşımlarlar da önerilen çalışmaya dahil edilerek uygulamaya özgü optimal kanal-ritim seçim performansı artırılabilir.
- EEG kanal seçimi, özellik seçimi vb gibi çeşitli uygulamalar için önerilen ayrık optimizasyon algoritmalarının daha az rastgeleliğe dayalı daha etkin dönüşüm teknikleri, hesaplama süresini azaltmak ve kanal seçimi sırasında performansı artırmak için gerçekleştirilebilir. Ayrıca, klinisyenlere ve araştırmacılara güven sağlamak için yapay zeka (XAI) teknikleri araştırılabilir.
- Pek çok alanda yaygın bir şekilde kullanılan ve oldukça etkin olan metasezgisel yöntemlerin keşif ve sömürü fazlarının geliştirilmesi ve bu iki fazın dengesinin sağlanması amacıyla farklı stratejiler geliştirilerek yöntemlere entegre edilebilir. Böylece bu yöntemlerin daha geniş alandaki uygulamalarda başarımlarının artırılması sağlanabilir.

Bu satırın altında “Bölüm Sonu (Sonraki Sayfa)” gizli bilgisi bulunmaktadır

KAYNAKLAR

- [1] M. P. Manda and H. S. Kim, "A Fast Image Thresholding Algorithm for Infrared Images Based on Histogram Approximation and Circuit Theory," *Algorithms*, vol. 13, no. 9, p. 207, Aug. 2020, doi: 10.3390/a13090207.
- [2] I. Y. Maolood, Y. E. A. Al-Salhi, and S. Lu, "Thresholding for Medical Image Segmentation for Cancer using Fuzzy Entropy with Level Set Algorithm," *Open Med (Wars)*, vol. 13, pp. 374–383, Sep. 2018, doi: 10.1515/med-2018-0056.
- [3] T. L. Luo *et al.*, "A Sensitive Thresholding Method for Confocal Laser Scanning Microscope Image Stacks of Microbial Biofilms," *Sci Rep*, vol. 8, no. 1, p. 13013, Dec. 2018, doi: 10.1038/s41598-018-31012-5.
- [4] L. Shen, X. Huang, and C. Fan, "Double-Group Particle Swarm Optimization and Its Application in Remote Sensing Image Segmentation," *Sensors*, vol. 18, no. 5, Art. no. 5, May 2018, doi: 10.3390/s18051393.
- [5] M. Tuba, "Multilevel image thresholding by nature-inspired algorithms: A short review," *Comput. Sci. J. Moldova*, vol. 22, pp. 318–338, 2014.
- [6] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Computer Vision, Graphics, and Image Processing*, vol. 29, no. 3, pp. 273–285, Mar. 1985, doi: 10.1016/0734-189X(85)90125-2.
- [7] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," p. 5.
- [8] X. Yang *et al.*, "Multi-level threshold segmentation framework for breast cancer images using enhanced differential evolution," *Biomedical Signal Processing and Control*, vol. 80, p. 104373, Feb. 2023, doi: 10.1016/j.bspc.2022.104373.
- [9] S. Agrawal, R. Panda, P. Choudhury, and A. Abraham, "Dominant color component and adaptive whale optimization algorithm for multilevel thresholding of color images," *Knowledge-Based Systems*, vol. 240, p. 108172, Mar. 2022, doi: 10.1016/j.knosys.2022.108172.
- [10] Y. Olmez, G. O. Koca, and Z. H. Akpolat, "Clonal selection algorithm based control for two-wheeled self-balancing mobile robot," *Simulation Modelling Practice and Theory*, vol. 118, p. 102552, Jul. 2022, doi: 10.1016/j.simpat.2022.102552.
- [11] Ö. İnik, "CNN hyper-parameter optimization for environmental sound classification," *Applied Acoustics*, vol. 202, p. 109168, Jan. 2023, doi: 10.1016/j.apacoust.2022.109168.
- [12] R. Mohakud and R. Dash, "Skin cancer image segmentation utilizing a novel EN-GWO based hyper-parameter optimized FCEDN," *Journal of King Saud University - Computer and Information Sciences*, vol. 34, no. 10, Part B, pp. 9889–9904, Nov. 2022, doi: 10.1016/j.jksuci.2021.12.018.
- [13] M. Wang *et al.*, "Lupus nephritis diagnosis using enhanced moth flame algorithm with support vector machines," *Computers in Biology and Medicine*, vol. 145, p. 105435, Jun. 2022, doi: 10.1016/j.combiomed.2022.105435.
- [14] S. Yadav, R. Yadav, A. Kumar, and M. Kumar, "A novel approach for optimal design of digital FIR filter using grasshopper optimization algorithm," *ISA Transactions*, vol. 108, pp. 196–206, Feb. 2021, doi: 10.1016/j.isatra.2020.08.032.
- [15] I. H. Hassan, A. Mohammed, Y. S. Ali, I. Jeremiah, and S. A. Abdulraheem, "Chapter 7 - Metaheuristic algorithms in text clustering," in *Comprehensive Metaheuristics*, S. Mirjalili and A. H. Gandomi, Eds., Academic Press, 2023, pp. 131–152. doi: 10.1016/B978-0-323-91781-0.00007-7.
- [16] T. Dokeroglu, A. Deniz, and H. E. Kiziloğlu, "A comprehensive survey on recent metaheuristics for feature selection," *Neurocomputing*, vol. 494, pp. 269–296, Jul. 2022, doi: 10.1016/j.neucom.2022.04.083.
- [17] S. Manikandan, K. Ramar, M. Willjuice Iruthayarajan, and K. G. Srinivasagan, "Multilevel thresholding for segmentation of medical brain images using real coded genetic algorithm," *Measurement*, vol. 47, pp. 558–568, Jan. 2014, doi: 10.1016/j.measurement.2013.09.031.

- [18] R. Kurban, A. Durmus, and E. Karakose, "A comparison of novel metaheuristic algorithms on color aerial image multilevel thresholding," *Engineering Applications of Artificial Intelligence*, vol. 105, p. 104410, Oct. 2021, doi: 10.1016/j.engappai.2021.104410.
- [19] M. Swain, T. T. Tripathy, R. Panda, S. Agrawal, and A. Abraham, "Differential exponential entropy-based multilevel threshold selection methodology for colour satellite images using equilibrium-cuckoo search optimizer," *Engineering Applications of Artificial Intelligence*, vol. 109, p. 104599, Mar. 2022, doi: 10.1016/j.engappai.2021.104599.
- [20] S. Agrawal, R. Panda, and A. Abraham, "A Novel Diagonal Class Entropy-Based Multilevel Image Thresholding Using Coral Reef Optimization," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 50, no. 11, pp. 4688–4696, Nov. 2020, doi: 10.1109/TSMC.2018.2859429.
- [21] R. Achanta, F. Estrada, P. Wils, and S. Süsstrunk, "Salient Region Detection and Segmentation," in *Computer Vision Systems*, Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, pp. 66–75.
- [22] X. Zhao, M. Turk, W. Li, K. Lien, and G. Wang, "A multilevel image thresholding segmentation algorithm based on two-dimensional K–L divergence and modified particle swarm optimization," *Applied Soft Computing*, vol. 48, pp. 151–159, Nov. 2016, doi: 10.1016/j.asoc.2016.07.016.
- [23] A. Ben Ishak, "A two-dimensional multilevel thresholding method for image segmentation," *Applied Soft Computing*, vol. 52, pp. 306–322, Mar. 2017, doi: 10.1016/j.asoc.2016.10.034.
- [24] S. Pare, A. Kumar, and G. K. Singh, "Color multilevel thresholding using gray-level co-occurrence matrix and differential evolution algorithm," in *2017 International Conference on Communication and Signal Processing (ICCSP)*, Apr. 2017, pp. 0096–0100. doi: 10.1109/ICCSP.2017.8286622.
- [25] S. Pare, A. Kumar, V. Bajaj, and G. K. Singh, "A context sensitive multilevel thresholding using swarm based algorithms," *IEEE/CAA Journal of Automatica Sinica*, vol. 6, no. 6, pp. 1471–1486, Nov. 2019, doi: 10.1109/JAS.2017.7510697.
- [26] D. Shao *et al.*, "Ultrasound image segmentation with multilevel threshold based on differential search algorithm," *IET Image Processing*, vol. 13, no. 6, pp. 998–1005, 2019, doi: 10.1049/iet-ipr.2018.6150.
- [27] A. K. Bhandari, V. K. Singh, A. Kumar, and G. K. Singh, "Cuckoo search algorithm and wind driven optimization based study of satellite image segmentation for multilevel thresholding using Kapur's entropy," *Expert Systems with Applications*, vol. 41, no. 7, pp. 3538–3560, Jun. 2014, doi: 10.1016/j.eswa.2013.10.059.
- [28] X. Bao, H. Jia, and C. Lang, "A Novel Hybrid Harris Hawks Optimization for Color Image Multilevel Thresholding Segmentation," *IEEE Access*, vol. 7, pp. 76529–76546, 2019, doi: 10.1109/ACCESS.2019.2921545.
- [29] H. Jia, J. Ma, and W. Song, "Multilevel Thresholding Segmentation for Color Image Using Modified Moth-Flame Optimization," *IEEE Access*, vol. 7, pp. 44097–44134, 2019, doi: 10.1109/ACCESS.2019.2908718.
- [30] S. Pare, A. K. Bhandari, A. Kumar, and G. K. Singh, "A new technique for multilevel color image thresholding based on modified fuzzy entropy and Lévy flight firefly algorithm," *Computers & Electrical Engineering*, vol. 70, pp. 476–495, Aug. 2018, doi: 10.1016/j.compeleceng.2017.08.008.
- [31] A. Wunna, M. Kumar Naik, R. Panda, B. Jena, and A. Abraham, "A differential evolutionary adaptive Harris hawks optimization for two dimensional practical Masi entropy-based multilevel image thresholding," *Journal of King Saud University - Computer and Information Sciences*, May 2020, doi: 10.1016/j.jksuci.2020.05.001.
- [32] Z. Xing, "An improved emperor penguin optimization based multilevel thresholding for color image segmentation," *Knowledge-Based Systems*, vol. 194, p. 105570, Apr. 2020, doi: 10.1016/j.knosys.2020.105570.
- [33] X. Yue and H. Zhang, "Modified hybrid bat algorithm with genetic crossover operation and smart inertia weight for multilevel image segmentation," *Applied Soft Computing*, vol. 90, p. 106157, May 2020, doi: 10.1016/j.asoc.2020.106157.

- [34] R. Srikanth and K. Bikshalu, "Multilevel thresholding image segmentation based on energy curve with harmony Search Algorithm," *Ain Shams Engineering Journal*, p. S2090447920301970, Oct. 2020, doi: 10.1016/j.asej.2020.09.003.
- [35] A. K. Bhandari, N. Singh, and I. V. Kumar, "Lightning search algorithm-based contextually fused multilevel image segmentation," *Applied Soft Computing*, vol. 91, p. 106243, Jun. 2020, doi: 10.1016/j.asoc.2020.106243.
- [36] P. Upadhyay and J. K. Chhabra, "Kapur's entropy based optimal multilevel image segmentation using Crow Search Algorithm," *Applied Soft Computing*, vol. 97, p. 105522, Dec. 2020, doi: 10.1016/j.asoc.2019.105522.
- [37] M. K. Naik, R. Panda, and A. Abraham, "Normalized square difference based multilevel thresholding technique for multispectral images using leader slime mould algorithm," *Journal of King Saud University - Computer and Information Sciences*, p. S1319157820305243, Nov. 2020, doi: 10.1016/j.jksuci.2020.10.030.
- [38] L. He and S. Huang, "An efficient krill herd algorithm for color image multilevel thresholding segmentation problem," *Applied Soft Computing*, vol. 89, p. 106063, Apr. 2020, doi: 10.1016/j.asoc.2020.106063.
- [39] M. Abd Elaziz, D. Yousri, M. A. A. Al-qaness, A. M. AbdelAty, A. G. Radwan, and A. A. Ewees, "A Grunwald–Letnikov based Manta ray foraging optimizer for global optimization and image segmentation," *Engineering Applications of Artificial Intelligence*, vol. 98, p. 104105, Feb. 2021, doi: 10.1016/j.engappai.2020.104105.
- [40] S. Singh, N. Mittal, and H. Singh, "A multilevel thresholding algorithm using LebTLBO for image segmentation," *Neural Comput & Applic*, vol. 32, no. 21, pp. 16681–16706, Nov. 2020, doi: 10.1007/s00521-020-04989-2.
- [41] Y. Xiao, Z. Cao, and S. Zhong, "New entropic thresholding approach using gray-level spatial correlation histogram," *OE*, vol. 49, no. 12, p. 127007, Dec. 2010, doi: 10.1117/1.3526333.
- [42] A. Yimit, Y. Hagihara, T. Miyoshi, and Y. Hagihara, "2-D direction histogram based entropic thresholding," *Neurocomputing*, vol. 120, pp. 287–297, Nov. 2013, doi: 10.1016/j.neucom.2012.10.031.
- [43] Y. Xiao, Z. Cao, and J. Yuan, "Entropic image thresholding based on GLGM histogram," *Pattern Recognition Letters*, vol. 40, pp. 47–55, Apr. 2014, doi: 10.1016/j.patrec.2013.12.017.
- [44] X. Zheng, H. Ye, and Y. Tang, "Image Bi-Level Thresholding Based on Gray Level-Local Variance Histogram," *Entropy*, vol. 19, no. 5, Art. no. 5, May 2017, doi: 10.3390/e19050191.
- [45] S. Yi, G. Zhang, J. He, and L. Tong, "Entropic Image Thresholding Segmentation Based on Gabor Histogram," *KSII Transactions on Internet and Information Systems*, vol. 13, no. 4, pp. 2113–2128, Apr. 2019.
- [46] Mittal H. and Saraswat M., "An optimum multi-level image thresholding segmentation using non-local means 2D histogram and exponential Kbest gravitational search algorithm," *Engineering Applications of Artificial Intelligence*, vol. 71, pp. 226–235, May 2018.
- [47] A. A. Ewees, M. Abd Elaziz, M. A. A. Al-Qaness, H. A. Khalil, and S. Kim, "Improved Artificial Bee Colony Using Sine-Cosine Algorithm for Multi-Level Thresholding Image Segmentation," *IEEE Access*, vol. 8, pp. 26304–26315, 2020, doi: 10.1109/ACCESS.2020.2971249.
- [48] X. Wang, J.-S. Pan, and S.-C. Chu, "A Parallel Multi-Verse Optimizer for Application in Multilevel Image Segmentation," *IEEE Access*, vol. 8, pp. 32018–32030, 2020, doi: 10.1109/ACCESS.2020.2973411.
- [49] Z. Zhang and J. Yin, "Bee Foraging Algorithm Based Multi-Level Thresholding For Image Segmentation," *IEEE Access*, vol. 8, pp. 16269–16280, 2020, doi: 10.1109/ACCESS.2020.2966665.
- [50] Z. Yan, J. Zhang, Z. Yang, and J. Tang, "Kapur's Entropy for Underwater Multilevel Thresholding Image Segmentation Based on Whale Optimization Algorithm," *IEEE Access*, vol. 9, pp. 41294–41319, 2021, doi: 10.1109/ACCESS.2020.3005452.

- [51] H. S. N. Alwerfali *et al.*, “A Multilevel Image Thresholding Based on Hybrid Salp Swarm Algorithm and Fuzzy Entropy,” *IEEE Access*, vol. 7, pp. 181405–181422, 2019, doi: 10.1109/ACCESS.2019.2959325.
- [52] A. K. Bhandari, A. Ghosh, and I. V. Kumar, “A local contrast fusion based 3D Otsu algorithm for multilevel image segmentation,” *IEEE/CAA Journal of Automatica Sinica*, vol. 7, no. 1, pp. 200–213, Jan. 2020, doi: 10.1109/JAS.2019.1911843.
- [53] K. Li and Z. Tan, “An Improved Flower Pollination Optimizer Algorithm for Multilevel Image Thresholding,” *IEEE Access*, vol. 7, pp. 165571–165582, 2019, doi: 10.1109/ACCESS.2019.2953494.
- [54] U. K. Malviya, “Tumor Detection in MRI Images using Modified Multi-level Otsu Thresholding (MLOT) and Cross-Correlation of Principle Components,” in *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, Mar. 2020, pp. 126–131. doi: 10.1109/ICCMC48092.2020.ICCMC-00026.
- [55] E. H. Houssein, D. A. Abdelkareem, M. M. Emam, M. A. Hameed, and M. Younan, “An efficient image segmentation method for skin cancer imaging using improved golden jackal optimization algorithm,” *Computers in Biology and Medicine*, vol. 149, p. 106075, Oct. 2022, doi: 10.1016/j.compbiomed.2022.106075.
- [56] L. Ren *et al.*, “Multi-level thresholding segmentation for pathological images: Optimal performance design of a new modified differential evolution,” *Computers in Biology and Medicine*, vol. 148, p. 105910, Sep. 2022, doi: 10.1016/j.compbiomed.2022.105910.
- [57] Wei zhu, L. Liu, F. Kuang, L. Li, S. Xu, and Y. Liang, “An efficient multi-threshold image segmentation for skin cancer using boosting whale optimizer,” *Computers in Biology and Medicine*, vol. 151, p. 106227, Dec. 2022, doi: 10.1016/j.compbiomed.2022.106227.
- [58] K. M. Hosny, A. M. Khalid, H. M. Hamza, and S. Mirjalili, “Multilevel segmentation of 2D and volumetric medical images using hybrid Coronavirus Optimization Algorithm,” *Computers in Biology and Medicine*, vol. 150, p. 106003, Nov. 2022, doi: 10.1016/j.compbiomed.2022.106003.
- [59] B. Jena, M. K. Naik, R. Panda, and A. Abraham, “Maximum 3D Tsallis entropy based multilevel thresholding of brain MR image using attacking Manta Ray foraging optimization,” *Engineering Applications of Artificial Intelligence*, vol. 103, p. 104293, Aug. 2021, doi: 10.1016/j.engappai.2021.104293.
- [60] X. Chen *et al.*, “An efficient multilevel thresholding image segmentation method based on the slime mould algorithm with bee foraging mechanism: A real case with lupus nephritis images,” *Computers in Biology and Medicine*, vol. 142, p. 105179, Mar. 2022, doi: 10.1016/j.compbiomed.2021.105179.
- [61] K. R. Scherer, “Emotions as Episodes of Subsystem Synchronization Driven by Nonlinear Appraisal Processes,” in *Emotion, Development, and Self-Organization: Dynamic Systems Approaches to Emotional Development*, I. Granic and M. D. Lewis, Eds., in Cambridge Studies in Social and Emotional Development. , Cambridge: Cambridge University Press, 2000, pp. 70–99. doi: 10.1017/CBO9780511527883.005.
- [62] D. Maheshwari, S. K. Ghosh, R. K. Tripathy, M. Sharma, and U. R. Acharya, “Automated accurate emotion recognition system using rhythm-specific deep convolutional neural network technique with multi-channel EEG signals,” *Computers in Biology and Medicine*, vol. 134, p. 104428, Jul. 2021, doi: 10.1016/j.compbiomed.2021.104428.
- [63] “PrimePatNet87: Prime pattern and tunable q-factor wavelet transform techniques for automated accurate EEG emotion recognition - ScienceDirect.” Accessed: Apr. 27, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0010482521006612>
- [64] B. Ari, K. Siddique, Ö. F. Alçin, M. Aslan, A. Şengür, and R. M. Mehmood, “Wavelet ELM-AE Based Data Augmentation and Deep Learning for Efficient Emotion Recognition Using EEG Recordings,” *IEEE Access*, vol. 10, pp. 72171–72181, 2022, doi: 10.1109/ACCESS.2022.3181887.

- [65] S. K. Khare, V. Bajaj, and G. R. Sinha, "Adaptive Tunable Q Wavelet Transform-Based Emotion Identification," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 12, pp. 9609–9617, Dec. 2020, doi: 10.1109/TIM.2020.3006611.
- [66] S. K. Khare and V. Bajaj, "An Evolutionary Optimized Variational Mode Decomposition for Emotion Recognition," *IEEE Sensors Journal*, vol. 21, no. 2, pp. 2035–2042, Jan. 2021, doi: 10.1109/JSEN.2020.3020915.
- [67] S. k. Khare, A. Nishad, A. Upadhyay, and V. Bajaj, "Classification of emotions from EEG signals using time-order representation based on the S-transform and convolutional neural network," *Electronics Letters*, vol. 56, no. 25, pp. 1359–1361, 2020, doi: 10.1049/el.2020.2380.
- [68] V. Bajaj, S. Taran, and A. Sengur, "Emotion classification using flexible analytic wavelet transform for electroencephalogram signals," *Health Inf Sci Syst*, vol. 6, no. 1, p. 12, Sep. 2018, doi: 10.1007/s13755-018-0048-y.
- [69] F. Demir, N. Sobahi, S. Siuly, and A. Sengur, "Exploring Deep Learning Features for Automatic Classification of Human Emotion Using EEG Rhythms," *IEEE Sensors J.*, vol. 21, no. 13, pp. 14923–14930, Jul. 2021, doi: 10.1109/JSEN.2021.3070373.
- [70] T. Tuncer, S. Dogan, M. Baygin, and U. Rajendra Acharya, "Tetromino pattern based accurate EEG emotion classification model," *Artificial Intelligence in Medicine*, vol. 123, p. 102210, Jan. 2022, doi: 10.1016/j.artmed.2021.102210.
- [71] A. M. Ismael, Ö. F. Alçin, K. H. Abdalla, and A. Şengür, "Two-stepped majority voting for efficient EEG-based emotion classification," *Brain Informatics*, vol. 7, no. 1, p. 9, Sep. 2020, doi: 10.1186/s40708-020-00111-3.
- [72] V. M. Joshi and R. B. Ghongade, "EEG based emotion detection using fourth order spectral moment and deep learning," *Biomedical Signal Processing and Control*, vol. 68, p. 102755, Jul. 2021, doi: 10.1016/j.bspc.2021.102755.
- [73] Q. Gao, Y. Yang, Q. Kang, Z. Tian, and Y. Song, "EEG-based Emotion Recognition with Feature Fusion Networks," *Int. J. Mach. Learn. & Cyber.*, vol. 13, no. 2, pp. 421–429, Feb. 2022, doi: 10.1007/s13042-021-01414-5.
- [74] X. Xing, Z. Li, T. Xu, L. Shu, B. Hu, and X. Xu, "SAE+LSTM: A New Framework for Emotion Recognition From Multi-Channel EEG," *Frontiers in Neurorobotics*, vol. 13, 2019, Accessed: Apr. 27, 2023. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fnbot.2019.00037>
- [75] D. Şengür and S. Siuly, "Efficient approach for EEG-based emotion recognition," *Electronics Letters*, vol. 56, no. 25, pp. 1361–1364, 2020, doi: 10.1049/el.2020.2685.
- [76] S. K. Mandal and M. N. B. Naskar, "Meta heuristic assisted automated channel selection model for motor imagery brain computer interface," *Multimed Tools Appl*, vol. 81, no. 12, pp. 17111–17130, May 2022, doi: 10.1007/s11042-022-12327-y.
- [77] Z. A. A. Alyasseri *et al.*, "EEG Channel Selection Based User Identification via Improved Flower Pollination Algorithm," *Sensors*, vol. 22, no. 6, Art. no. 6, Jan. 2022, doi: 10.3390/s22062092.
- [78] H. R. Hussien, E.-S. M. El-Kenawy, and A. I. El-Desouky, "EEG Channel Selection Using A Modified Grey Wolf Optimizer," *European Journal of Electrical Engineering and Computer Science*, vol. 5, no. 1, Art. no. 1, Jan. 2021, doi: 10.24018/ejece.2021.5.1.265.
- [79] Z. Wang, Z. Han, J. Zhao, and W. Wang, "Distributed robust scheduling optimization for energy system of steel industry considering prediction uncertainties," *Information Sciences*, p. 120431, Mar. 2024, doi: 10.1016/j.ins.2024.120431.
- [80] H. Yuan, Y. Wu, J. Zhang, S. Zhou, X. Lu, and Y. Zhang, "Integrated optimization of a turbine stage at a low Reynolds number via NURBS surface and machine learning," *Energy*, p. 130956, Mar. 2024, doi: 10.1016/j.energy.2024.130956.
- [81] L. Qiao, K. Liu, Y. Xue, W. Tang, and T. Salehnia, "A multi-level thresholding image segmentation method using hybrid Arithmetic Optimization and Harris Hawks Optimizer algorithms," *Expert Systems with Applications*, vol. 241, p. 122316, May 2024, doi: 10.1016/j.eswa.2023.122316.

- [82] Z. Li, B. Wang, B. Zhu, Q. Wang, and W. Zhu, "Thermal error modeling of electrical spindle based on optimized ELM with marine predator algorithm," *Case Studies in Thermal Engineering*, vol. 38, p. 102326, Oct. 2022, doi: 10.1016/j.csite.2022.102326.
- [83] M. Wojciuk, Z. Swiderska-Chadaj, K. Siwek, and A. Gertych, "Improving classification accuracy of fine-tuned CNN models: Impact of hyperparameter optimization," *Heliyon*, vol. 10, no. 5, p. e26586, Mar. 2024, doi: 10.1016/j.heliyon.2024.e26586.
- [84] S. Mirjalili, "Genetic Algorithm," in *Evolutionary Algorithms and Neural Networks: Theory and Applications*, S. Mirjalili, Ed., in Studies in Computational Intelligence. , Cham: Springer International Publishing, 2019, pp. 43–55. doi: 10.1007/978-3-319-93025-1_4.
- [85] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*, Nov. 1995, pp. 1942–1948 vol.4. doi: 10.1109/ICNN.1995.488968.
- [86] R. A. Rutenbar, "Simulated annealing algorithms: an overview," *IEEE Circuits and Devices Magazine*, vol. 5, no. 1, pp. 19–26, Jan. 1989, doi: 10.1109/101.17235.
- [87] M. Dorigo, M. Birattari, and T. Stutzle, "Ant colony optimization," *IEEE Computational Intelligence Magazine*, vol. 1, no. 4, pp. 28–39, Nov. 2006, doi: 10.1109/MCI.2006.329691.
- [88] R. Storn and K. Price, "Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces," *Journal of Global Optimization*, vol. 11, no. 4, pp. 341–359, Dec. 1997, doi: 10.1023/A:1008202821328.
- [89] E. Rashedi, H. Nezamabadi-pour, and S. Saryazdi, "GSA: A Gravitational Search Algorithm," *Information Sciences*, vol. 179, no. 13, pp. 2232–2248, Jun. 2009, doi: 10.1016/j.ins.2009.03.004.
- [90] D. Karaboga, "An Idea Based on Honey Bee Swarm for Numerical Optimization".
- [91] N. Chopra and M. Mohsin Ansari, "Golden jackal optimization: A novel nature-inspired optimizer for engineering applications," *Expert Systems with Applications*, vol. 198, p. 116924, Jul. 2022, doi: 10.1016/j.eswa.2022.116924.
- [92] F. A. Hashim, E. H. Houssein, K. Hussain, M. S. Mabrouk, and W. Al-Atabany, "Honey Badger Algorithm: New metaheuristic algorithm for solving optimization problems," *Mathematics and Computers in Simulation*, vol. 192, pp. 84–110, Feb. 2022, doi: 10.1016/j.matcom.2021.08.013.
- [93] L. Abualigah, D. Yousri, M. Abd Elaziz, A. A. Ewees, M. A. A. Al-qaness, and A. H. Gandomi, "Aquila Optimizer: A novel meta-heuristic optimization algorithm," *Computers & Industrial Engineering*, vol. 157, p. 107250, Jul. 2021, doi: 10.1016/j.cie.2021.107250.
- [94] M. Azizi, "Atomic orbital search: A novel metaheuristic algorithm," *Applied Mathematical Modelling*, vol. 93, pp. 657–683, May 2021, doi: 10.1016/j.apm.2020.12.021.
- [95] M. Jafari, E. Salajegheh, and J. Salajegheh, "Elephant clan optimization: A nature-inspired metaheuristic algorithm for the optimal design of structures," *Applied Soft Computing*, vol. 113, p. 107892, Dec. 2021, doi: 10.1016/j.asoc.2021.107892.
- [96] A. Kaveh and A. Dadras Eslamlou, "Water strider algorithm: A new metaheuristic and applications," *Structures*, vol. 25, pp. 520–541, Jun. 2020, doi: 10.1016/j.istruc.2020.03.033.
- [97] M. Abdel-Basset, R. Mohamed, M. Jameel, and M. Abouhawwash, "Nutcracker optimizer: A novel nature-inspired metaheuristic algorithm for global optimization and engineering design problems," *Knowledge-Based Systems*, vol. 262, p. 110248, Feb. 2023, doi: 10.1016/j.knosys.2022.110248.
- [98] J. O. Agushaka, A. E. Ezugwu, and L. Abualigah, "Gazelle optimization algorithm: a novel nature-inspired metaheuristic optimizer," *Neural Comput & Applic*, vol. 35, no. 5, pp. 4099–4131, Feb. 2023, doi: 10.1007/s00521-022-07854-6.
- [99] D. Maden, E. Çelik, E. H. Houssein, and G. Sharma, "Squirrel search algorithm applied to effective estimation of solar PV model parameters: a real-world practice," *Neural Comput & Applic*, vol. 35, no. 18, pp. 13529–13546, Jun. 2023, doi: 10.1007/s00521-023-08451-x.
- [100] S. Saremi, S. Mirjalili, and A. Lewis, "Grasshopper Optimisation Algorithm: Theory and application," *Advances in Engineering Software*, vol. 105, pp. 30–47, Mar. 2017, doi: 10.1016/j.advengsoft.2017.01.004.

- [101] A. Mohammadi-Balani, M. Dehghan Nayeri, A. Azar, and M. Taghizadeh-Yazdi, "Golden eagle optimizer: A nature-inspired metaheuristic algorithm," *Computers & Industrial Engineering*, vol. 152, p. 107050, Feb. 2021, doi: 10.1016/j.cie.2020.107050.
- [102] L. Abualigah, A. Diabat, S. Mirjalili, M. Abd Elaziz, and A. H. Gandomi, "The Arithmetic Optimization Algorithm," *Computer Methods in Applied Mechanics and Engineering*, vol. 376, p. 113609, Apr. 2021, doi: 10.1016/j.cma.2020.113609.
- [103] F. A. Hashim, E. H. Houssein, M. S. Mabrouk, W. Al-Atabany, and S. Mirjalili, "Henry gas solubility optimization: A novel physics-based algorithm," *Future Generation Computer Systems*, vol. 101, pp. 646–667, Dec. 2019, doi: 10.1016/j.future.2019.07.015.
- [104] Q. Zhang, R. Wang, J. Yang, K. Ding, Y. Li, and J. Hu, "Collective decision optimization algorithm: A new heuristic optimization method," *Neurocomputing*, vol. 221, pp. 123–137, Jan. 2017, doi: 10.1016/j.neucom.2016.09.068.
- [105] M. Kumar, A. J. Kulkarni, and S. C. Satapathy, "Socio evolution & learning optimization algorithm: A socio-inspired optimization methodology," *Future Generation Computer Systems*, vol. 81, pp. 252–272, Apr. 2018, doi: 10.1016/j.future.2017.10.052.
- [106] R. Moghdani and K. Salimifard, "Volleyball Premier League Algorithm," *Applied Soft Computing*, vol. 64, pp. 161–185, Mar. 2018, doi: 10.1016/j.asoc.2017.11.043.
- [107] A. Faramarzi, M. Heidarinejad, S. Mirjalili, and A. H. Gandomi, "Marine Predators Algorithm: A nature-inspired metaheuristic," *Expert Systems with Applications*, vol. 152, p. 113377, Aug. 2020, doi: 10.1016/j.eswa.2020.113377.
- [108] Y. Ölmez, A. Sengur, and G. Ozmen Koca, "Multilevel thresholding with metaheuristic methods," *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 36, pp. 213–224, Jul. 2020, doi: 10.17341/gazimmfd.727811.
- [109] Y. Olmez, A. Sengur, G. O. Koca, and R. V. Rao, "An adaptive multilevel thresholding method with chaotically-enhanced Rao algorithm," *Multimed Tools Appl*, Sep. 2022, doi: 10.1007/s11042-022-13671-9.
- [110] Y. Olmez, G. O. Koca, E. Tanyildizi, and A. Sengur, "Multilevel image thresholding based on Renyi's entropy and golden sinus algorithm II," *Neural Comput & Applic*, May 2023, doi: 10.1007/s00521-023-08658-y.
- [111] Y. Olmez, G. O. Koca, A. Sengur, and U. R. Acharya, "PS-VTS: particle swarm with visit table strategy for automated emotion recognition with EEG signals," *Health Inf Sci Syst*, vol. 11, no. 1, p. 22, May 2023, doi: 10.1007/s13755-023-00224-z.
- [112] Y. Olmez, G. O. Koca, A. Sengür, U. R. Acharya, and H. Mir, "Improved PSO With Visit Table and Multiple Direction Search Strategies for Skin Cancer Image Segmentation," *IEEE Access*, vol. 12, pp. 840–867, 2024, doi: 10.1109/ACCESS.2023.3347587.
- [113] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," *ACM Comput. Surv.*, vol. 35, no. 3, pp. 268–308, Sep. 2003, doi: 10.1145/937503.937505.
- [114] S. Mirjalili and A. Lewis, "The Whale Optimization Algorithm," *Advances in Engineering Software*, vol. 95, pp. 51–67, May 2016, doi: 10.1016/j.advengsoft.2016.01.008.
- [115] Z. Beheshti, S. Mariyam, and H. Shamsuddin, "Shamsuddin: A Review of Population-based Meta-Heuristic Algorithm," *Int. J. Adv. Soft Comput. Appl.*, vol. 5, no. 1, pp. 1–35, 2013.
- [116] A. Kumar and S. Bawa, "Generalized Ant Colony Optimizer: swarm-based meta-heuristic algorithm for cloud services execution," *Computing*, vol. 101, no. 11, pp. 1609–1632, Nov. 2019, doi: 10.1007/s00607-018-0674-x.
- [117] A. Kumar and S. Bawa, "A comparative review of meta-heuristic approaches to optimize the SLA violation costs for dynamic execution of cloud services," *Soft Comput*, vol. 24, no. 6, pp. 3909–3922, Mar. 2020, doi: 10.1007/s00500-019-04155-4.
- [118] A. M. Shaheen, S. R. Spea, S. M. Farrag, and M. A. Abido, "A review of meta-heuristic algorithms for reactive power planning problem," *Ain Shams Engineering Journal*, vol. 9, no. 2, pp. 215–231, Jun. 2018, doi: 10.1016/j.asej.2015.12.003.
- [119] J. Dréo, J.-P. Aumasson, W. Tfaili, and P. Siarry, "Adaptive learning search, a new tool to help comprehending metaheuristics," *International Journal on Artificial Intelligence Tools*, vol. 16, no. 3, pp. 483–505, 2007, doi: 10.1142/S0218213007003370.

- [120] A. G. Hussien, M. Amin, and M. Abd El Aziz, "A comprehensive review of moth-flame optimisation: variants, hybrids, and applications," *Journal of Experimental & Theoretical Artificial Intelligence*, vol. 32, no. 4, pp. 705–725, Jul. 2020, doi: 10.1080/0952813X.2020.1737246.
- [121] M. Abdel-Basset, L. Abdel-Fatah, and A. K. Sangaiah, "Chapter 10 - Metaheuristic Algorithms: A Comprehensive Review," in *Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications*, A. K. Sangaiah, M. Sheng, and Z. Zhang, Eds., in *Intelligent Data-Centric Systems*, Academic Press, 2018, pp. 185–231. doi: 10.1016/B978-0-12-813314-9.00010-4.
- [122] J. H. Holland, *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. MIT Press, 1992.
- [123] P. Moscato, "On Evolution, Search, Optimization, Genetic Algorithms and Martial Arts - Towards Memetic Algorithms," *Caltech Concurrent Computation Program*, Oct. 2000.
- [124] S. Mirjalili, S. M. Mirjalili, and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software*, vol. 69, pp. 46–61, Mar. 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [125] D. Karaboga, "Artificial bee colony algorithm," *Scholarpedia*, vol. 5, no. 3, p. 6915, Mar. 2010, doi: 10.4249/scholarpedia.6915.
- [126] R. A. Formato, "Central force optimization: A new metaheuristic with applications in applied electromagnetics," *Progress in Electromagnetics Research*, vol. 77, pp. 425–491, 2007, doi: 10.2528/PIER07082403.
- [127] R. V. Rao, V. J. Savsani, and D. P. Vakharia, "Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems," *Computer-Aided Design*, vol. 43, no. 3, pp. 303–315, Mar. 2011, doi: 10.1016/j.cad.2010.12.015.
- [128] R. V. Rao, V. J. Savsani, and D. P. Vakharia, "Teaching–Learning-Based Optimization: An optimization method for continuous non-linear large scale problems," *Information Sciences*, vol. 183, no. 1, pp. 1–15, Jan. 2012, doi: 10.1016/j.ins.2011.08.006.
- [129] "A New Heuristic Optimization Algorithm: Harmony Search - Zong Woo Geem, Joong Hoon Kim, G.V. Loganathan, 2001." Accessed: May 02, 2023. [Online]. Available: <https://journals.sagepub.com/doi/abs/10.1177/003754970107600201?journalCode=simb>
- [130] F. Glover, "Tabu Search—Part I," *ORSA Journal on Computing*, vol. 1, no. 3, pp. 190–206, Aug. 1989, doi: 10.1287/ijoc.1.3.190.
- [131] "Tabu Search—Part II | ORSA Journal on Computing." Accessed: May 02, 2023. [Online]. Available: <https://pubsonline.informs.org/doi/10.1287/ijoc.2.1.4>
- [132] S. He, Q. H. Wu, and J. R. Saunders, "Group search optimizer: An optimization algorithm inspired by animal searching behavior," *IEEE Transactions on Evolutionary Computation*, vol. 13, no. 5, pp. 973–990, 2009, doi: 10.1109/TEVC.2009.2011992.
- [133] E. Tanyıldızı, "A novel optimization method for solving constrained and unconstrained problems: modified Golden Sine Algorithm," *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 26, no. 6, pp. 3287–3304, Jan. 2018, doi: 10.3906/elk-1802-232.
- [134] R. V. Rao, "Rao algorithms: Three metaphor-less simple algorithms for solving optimization problems," *International Journal of Industrial Engineering Computations*, vol. 11, pp. 107–130, 2020, doi: 10.5267/j.ijiec.2019.6.002.
- [135] H. Mittal and M. Saraswat, "An optimum multi-level image thresholding segmentation using non-local means 2D histogram and exponential Kbest gravitational search algorithm," *Engineering Applications of Artificial Intelligence*, vol. 71, pp. 226–235, May 2018.
- [136] L. Zhang, L. Zhang, X. Mou, and D. Zhang, "FSIM: A Feature Similarity Index for Image Quality Assessment," *IEEE Transactions on Image Processing*, vol. 20, no. 8, pp. 2378–2386, Aug. 2011, doi: 10.1109/TIP.2011.2109730.
- [137] Sasi varnan C., K. J. Jagan A., Jyoti D., and Rao Dr.D.S., "Image Quality Assessment Techniques pn Spatial Domain," *International Journal of Computer Science and Technology*, vol. 2, no. 3, pp. 177–184, Sep. 2011.
- [138] H. Liang, H. Jia, Z. Xing, J. Ma, and X. Peng, "Modified Grasshopper Algorithm-Based Multilevel Thresholding for Color Image Segmentation," *IEEE Access*, vol. 7, pp. 11258–11295, 2019, doi: 10.1109/ACCESS.2019.2891673.

- [139] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600–612, Apr. 2004, doi: 10.1109/TIP.2003.819861.
- [140] B. S. Sathya and Manavalan R., "Image Segmentation by Clustering Methods: Performance Analysis," *International Journal of Computer Applications*, vol. 29, no. 11, pp. 27–32, 2011, doi: <https://doi.org/10.5120/3688-5127>.
- [141] "The Berkeley Segmentation Dataset and Benchmark." Accessed: Nov. 15, 2023. [Online]. Available: <https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>
- [142] "ISIC Dataset." [Online]. Available: <https://challenge.isic-archive.com/data/#2017>
- [143] H. Bolhasani, E. Amjadi, M. Tabatabaeian, and S. J. Jassbi, "A histopathological image dataset for grading breast invasive ductal carcinomas," *Informatics in Medicine Unlocked*, vol. 19, p. 100341, Jan. 2020, doi: 10.1016/j.imu.2020.100341.
- [144] "DEAP Dataset." [Online]. Available: <https://www.eecs.qmul.ac.uk/mmv/datasets/deap/>
- [145] N. Pavesic and S. Ribaric, "Gray level thresholding using the Havrda and Charvat entropy," in *2000 10th Mediterranean Electrotechnical Conference. Information Technology and Electrotechnology for the Mediterranean Countries. Proceedings. MeleCon 2000 (Cat. No.00CH37099)*, May 2000, pp. 631–634 vol.2. doi: 10.1109/MELCON.2000.880013.
- [146] M. Portes de Albuquerque, I. A. Esquef, A. R. Gesualdi Mello, and M. Portes de Albuquerque, "Image thresholding using Tsallis entropy," *Pattern Recognition Letters*, vol. 25, no. 9, pp. 1059–1065, Jul. 2004, doi: 10.1016/j.patrec.2004.03.003.
- [147] "Rényi : On Measures of Entropy and Information." Accessed: Mar. 02, 2020. [Online]. Available: <https://projecteuclid.org/euclid.bsmmsp/1200512181>
- [148] P. K. Sahoo, S. Soltani, and A. K. C. Wong, "A survey of thresholding techniques," *Computer Vision, Graphics, and Image Processing*, vol. 41, no. 2, pp. 233–260, Feb. 1988, doi: 10.1016/0734-189X(88)90022-9.
- [149] P. K. Sahoo and G. Arora, "Image thresholding using two-dimensional Tsallis–Havrda–Charvát entropy," *Pattern Recognition Letters*, vol. 27, no. 6, pp. 520–528, Apr. 2006, doi: 10.1016/j.patrec.2005.09.017.
- [150] H. Moazen, S. Molaei, L. Farzinvas, and M. Sabaei, "PSO-ELPM: PSO with elite learning, enhanced parameter updating, and exponential mutation operator," *Information Sciences*, vol. 628, pp. 70–91, May 2023, doi: 10.1016/j.ins.2023.01.103.
- [151] W. Zhao, L. Wang, and S. Mirjalili, "Artificial hummingbird algorithm: A new bio-inspired optimizer with its engineering applications," *Computer Methods in Applied Mechanics and Engineering*, vol. 388, p. 114194, Jan. 2022, doi: 10.1016/j.cma.2021.114194.
- [152] Z. A. A. Alyasseri *et al.*, "EEG Channel Selection for Person Identification Using Binary Grey Wolf Optimizer," *IEEE Access*, vol. 10, pp. 10500–10513, 2022, doi: 10.1109/ACCESS.2021.3135805.
- [153] M. A. Khanesar, M. Teshnehlab, and M. A. Shoorehdeli, "A novel binary particle swarm optimization," in *2007 Mediterranean Conference on Control & Automation*, Jun. 2007, pp. 1–6. doi: 10.1109/MED.2007.4433821.
- [154] L. B. Iantovics, "Black-Box-Based Mathematical Modelling of Machine Intelligence Measuring," *Mathematics*, vol. 9, no. 6, Art. no. 6, Jan. 2021, doi: 10.3390/math9060681.
- [155] H. Bingol and B. Alatas, "Chaos based optics inspired optimization algorithms as global solution search approach," *Chaos, Solitons & Fractals*, vol. 141, p. 110434, Dec. 2020, doi: 10.1016/j.chaos.2020.110434.
- [156] H. Muthusamy, S. Ravindran, S. Yaacob, and K. Polat, "An improved elephant herding optimization using sine–cosine mechanism and opposition based learning for global optimization problems," *Expert Systems with Applications*, vol. 172, p. 114607, Jun. 2021, doi: 10.1016/j.eswa.2021.114607.
- [157] W. Guo, W. Li, Q. Zhang, L. Wang, Q. Wu, and H. Ren, "Biogeography-based particle swarm optimization with fuzzy elitism and its applications to constrained engineering problems," *Engineering Optimization*, vol. 46, no. 11, pp. 1465–1484, Nov. 2014, doi: 10.1080/0305215X.2013.854349.

- [158] S. Mirjalili, A. H. Gandomi, S. Z. Mirjalili, S. Saremi, H. Faris, and S. M. Mirjalili, "Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems," *Advances in Engineering Software*, vol. 114, pp. 163–191, Dec. 2017, doi: 10.1016/j.advengsoft.2017.07.002.
- [159] Q. He and L. Wang, "An effective co-evolutionary particle swarm optimization for constrained engineering design problems," *Engineering Applications of Artificial Intelligence*, vol. 20, no. 1, pp. 89–99, Feb. 2007, doi: 10.1016/j.engappai.2006.03.003.
- [160] H. Mittal, R. Pal, A. Kulhari, and M. Saraswat, "Chaotic Kbest gravitational search algorithm (CKGSA)," in *2016 Ninth International Conference on Contemporary Computing (IC3)*, Noida, India, Aug. 2016, pp. 1–6. doi: 10.1109/IC3.2016.7880252.
- [161] V. Feoktistov, Ed., "Differential Evolution," in *Differential Evolution: In Search of Solutions*, in Springer Optimization and Its Applications. , Boston, MA: Springer US, 2006, pp. 1–24. doi: 10.1007/978-0-387-36896-2_1.
- [162] D. Karaboga and B. Basturk, "Artificial Bee Colony (ABC) Optimization Algorithm for Solving Constrained Optimization Problems," in *Foundations of Fuzzy Logic and Soft Computing*, in Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2007, pp. 789–798. doi: 10.1007/978-3-540-72950-1_77.
- [163] S. Mirjalili, "Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm," *Knowledge-Based Systems*, vol. 89, pp. 228–249, Nov. 2015, doi: 10.1016/j.knosys.2015.07.006.
- [164] S. Mirjalili, S. M. Mirjalili, and A. Hatamlou, "Multi-Verse Optimizer: a nature-inspired algorithm for global optimization," *Neural Comput & Applic*, vol. 27, no. 2, pp. 495–513, Feb. 2016, doi: 10.1007/s00521-015-1870-7.
- [165] R. Gupta, K. ur Rehman Laghari, and T. H. Falk, "Relevance vector classifier decision fusion and EEG graph-theoretic features for automatic affective state characterization," *Neurocomputing*, vol. 174, pp. 875–884, Jan. 2016, doi: 10.1016/j.neucom.2015.09.085.
- [166] N. Zhuang, Y. Zeng, L. Tong, C. Zhang, H. Zhang, and B. Yan, "Emotion Recognition from EEG Signals Using Multidimensional Information in EMD Domain," *BioMed Research International*, vol. 2017, p. e8317357, Aug. 2017, doi: 10.1155/2017/8317357.
- [167] P. Arnau-González, M. Arevalillo-Herráez, and N. Ramzan, "Fusing highly dimensional energy and connectivity features to identify affective states from EEG signals," *Neurocomputing*, vol. 244, pp. 81–89, Jun. 2017, doi: 10.1016/j.neucom.2017.03.027.
- [168] Y. Yang, Q. Wu, M. Qiu, Y. Wang, and X. Chen, "Emotion Recognition from Multi-Channel EEG through Parallel Convolutional Recurrent Neural Network," in *2018 International Joint Conference on Neural Networks (IJCNN)*, Jul. 2018, pp. 1–7. doi: 10.1109/IJCNN.2018.8489331.
- [169] P. Sarma and S. Barma, "Emotion recognition by distinguishing appropriate EEG segments based on random matrix theory," *Biomedical Signal Processing and Control*, vol. 70, p. 102991, Sep. 2021, doi: 10.1016/j.bspc.2021.102991.
- [170] R. Li, C. Ren, X. Zhang, and B. Hu, "A novel ensemble learning method using multiple objective particle swarm optimization for subject-independent EEG-based emotion recognition," *Computers in Biology and Medicine*, vol. 140, p. 105080, Jan. 2022, doi: 10.1016/j.compbiomed.2021.105080.
- [171] Z. He, Y. Zhong, and J. Pan, "An adversarial discriminative temporal convolutional network for EEG-based cross-domain emotion recognition," *Computers in Biology and Medicine*, vol. 141, p. 105048, Feb. 2022, doi: 10.1016/j.compbiomed.2021.105048.
- [172] J. Li *et al.*, "Cross-subject EEG emotion recognition combined with connectivity features and meta-transfer learning," *Computers in Biology and Medicine*, vol. 145, p. 105519, Jun. 2022, doi: 10.1016/j.compbiomed.2022.105519.
- [173] Z. Yan, J. Zhou, and W.-F. Wong, "EEG classification with spiking neural network: Smaller, better, more energy efficient," *Smart Health*, vol. 24, p. 100261, Jun. 2022, doi: 10.1016/j.smhl.2021.100261.

- [174] C. Li *et al.*, “Emotion recognition from EEG based on multi-task learning with capsule network and attention mechanism,” *Computers in Biology and Medicine*, vol. 143, p. 105303, Apr. 2022, doi: 10.1016/j.combiomed.2022.105303.
- [175] J. Li, X. Wu, Y. Zhang, H. Yang, and X. Wu, “DRS-Net: A spatial–temporal affective computing model based on multichannel EEG data,” *Biomedical Signal Processing and Control*, vol. 76, p. 103660, Jul. 2022, doi: 10.1016/j.bspc.2022.103660.
- [176] J. Cheng *et al.*, “Emotion Recognition From Multi-Channel EEG via Deep Forest,” *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 2, pp. 453–464, Feb. 2021, doi: 10.1109/JBHI.2020.2995767.



EKLER

Ek- 1: Test Fonksiyonları ve Özellikleri (F₁-F₂₃)

No	Fonksiyon adı	Formül	F _{opt}	Tür	Aralık	D
F ₁	Stepint	$f(x) = 25 + \sum_{i=1}^n x_i$	0	Unimodal-Separable	[-5.12,5.12]	5
F ₂	Step	$f(x) = \sum_{i=1}^n (x_i + 0.5)^2$	0	Unimodal-Separable	[-100,100]	30
F ₃	Sphere	$f(x) = \sum_{i=1}^n (x_i)^2$	0	Unimodal-Separable	[-100,100]	30
F ₄	Sumsquares	$f(x) = \sum_{i=1}^n (ix_i)^2$	0	Unimodal-Separable	[-10,10]	30
F ₅	Quartic	$f(x) = \sum_{i=1}^n ix_i^4$	0	Unimodal, Separable	[-1.28,1.28]	D
F ₆	Beale	$f(x) = (1.5 - x_1 + x_1x_2)^2 + (2.25 - x_1 + x_1x_2^2)^2$	0	Unimodal, Non-separable	[-4.5,4.5]	5
F ₇	Easom	$f(x) = -\cos(x_1)\cos(x_2)e^{-(x_1-\pi)^2-(x_2-\pi)^2}$	-1	Unimodal, Non-separable	[-100,100]	2
F ₈	Matyas	$f(x) = 0.26(x_1^2 + x_2^2) - 0.48x_1^2x_2^2$	0	Unimodal, Non-separable	[-10,10]	2
F ₉	Colville	$f(x) = 100(x_1 - x_2)^2 + (x_1 - 1)^2 + (x_4 - 1)^2 + 90(x_3^2 - x_4)^2 + 10.1((x_2 - 1)^2 + ((x_4 - 1)^2))$	0	Unimodal, Non-separable	[-10,10]	4
F ₁₀	Trid6	$f(x) = \sum_{i=1}^n (x_i - 1)^2 + \sum_{i=2}^n x_i x_{i-1}$	-50	Unimodal, Non-separable	[-D ² , D ²]	6
F ₁₁	Trid10	$f(x) = \sum_{i=1}^n (x_i - 1)^2 + \sum_{i=2}^n x_i x_{i-1}$	-210	Unimodal, Non-separable	[-D ² , D ²]	10
F ₁₂	Zakharov	$f(x) = \sum_{i=1}^n x_i^2 + (\frac{1}{2} \sum_{i=1}^n ix_i)^2 + (\frac{1}{2} \sum_{i=1}^n ix_i)^4$	0	Unimodal, Non-separable	[-5,10]	10
F ₁₃	Powell	$f(x) = \sum_{i=1}^{n/k} (x_{4i-3} + 10x_{4i-2})^2 + 5(x_{4i-1} + 10x_4)^2 + 5(x_{4i-2} + 10x_{4i-1})^4 + (x_{4i-1} + 10x_4)^4$	0	Unimodal, Non-separable	[-4,5]	24
F ₁₄	Schwefel 2.22	$f(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	0	Unimodal, Non-separable	[-10,10]	30
F ₁₅	Schwefel 1.2	$f(x) = \sum_{i=1}^n (\sum_{j=1}^n x_j)^2$	0	Unimodal, Non-separable	[-100,100]	30
F ₁₆	Rosenbrock	$f(x) = \sum_{i=1}^{D-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$	00	Unimodal, Non-separable	[-30,30]	30
F ₁₇	Dixon-Price	$f(x) = (x_1 - 1)^2 + \sum_{i=2}^n i(x_i^2 - x_{i-1})^2$	0	Unimodal, Non-separable	[-10,10]	30
F ₁₈	Foxholes	$f(x) = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^{25} (x_i - a_{ij})^6} \right]^{-1}$	0	Multimodal, Separable	[-65.536, 65.536]	2
F ₁₉	Branin	$f(x) = x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5.1}{\pi} x_1 - 6)^2 + 10 \left(1 - \frac{1}{8\pi} \right) \cos x_1 + 10$	0.998	Multimodal, Separable	[-5,10] x [0,15]	2
F ₂₀	Bohachevsky1	$f(x) = x_1^2 + 2x_2^2 - 0.3 \cos(3\pi x_1) - 0.4 \cos(4\pi x_2) + 0.7$	0.398	Multimodal, Separable	[-100,100]	2
F ₂₁	Booth	$f(x) = x_1^2 + 2x_2^2 - 7)^2 + (2x_1 + x_2 - 5)^2$	0	Multimodal, Separable	[-10,10]	2
F ₂₂	Rastrigin	$f(x) = -\sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$	0	Multimodal, Separable	[-5.12,5.12]	30

Ek- 2: Test Fonksiyonları ve Özellikleri (F₂₃-F₄₂)

No	Fonksiyon adı	Formül	F _{opt}	Tür	Arahk	D
F ₂₃	Schwefel	$f(x) = -\sum_{i=1}^n x_i \sin(\sqrt{ x })$	0	Multimodal, Separable	[-500,500]	30
F ₂₄	Michalewicz2	$f(x) = -\sum_{i=1}^n \sin(x_i) \left(\sin\left(\frac{ix_i^2}{\pi}\right)\right)^{20}$	-12569	Multimodal, Separable	[0,π]	2
F ₂₅	Michalewicz5	$f(x) = -\sum_{i=1}^n \sin(x_i) \left(\sin\left(\frac{ix_i^2}{\pi}\right)\right)^{20}$	-1.80	Multimodal, Separable	[0,π]	5
F ₂₆	Michalewicz10	$f(x) = -\sum_{i=1}^n \sin(x_i) \left(\sin\left(\frac{ix_i^2}{\pi}\right)\right)^{20}$	-4.68	Multimodal, Separable	[0,π]	10
F ₂₇	Schaffer	$f(x) = 0.5 + \frac{\sin^2(\sqrt{x_1^2 + x_2^2}) - 0.5}{(1 + 0.001(x_1^2 + x_2^2))^2}$	-9.66	Multimodal, Non-Separable	[-100,100]	2
F ₂₈	Six Hump Camel Back	$f(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	0	Multimodal, Non-Separable	[-5,5]	2
F ₂₉	Bohachevsky2	$f(x) = x_1^2 - 2x_2^2 + 0.3 \cos(3\pi x_1) (4\pi x_3) + 0.3$	-1.0316	Multimodal, Non-Separable	[-100,100]	2
F ₃₀	Bohachevsky3	$f(x) = x_1^2 - 2x_2^2 + 0.3 \cos(3\pi x_1) (4\pi x_3) + 0.3$	0	Multimodal, Non-Separable	[-100,100]	2
F ₃₁	Shubert	$f(x) = \left(\sum_{i=1}^5 i \cos(i+1)x_1 + i\right) + \left(\sum_{i=1}^5 i \cos(i+1)x_2 + i\right)$	-186.73	Multimodal, Non-Separable	[-10,10]	2
F ₃₂	Goldstein– Price	$f(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^1 - 14x_2 + 6x_1x_2 + 3x_2^2)]$	3	Multimodal, Non-Separable	[-2,2]	2
F ₃₃	Kowalik	$f(x) = \sum_{i=1}^{11} \left a_i - \frac{x_1(b_i^2 + b_ix_2)}{b_i^2 + b_ix_3 + x_4} \right ^2$	0.00031	Multimodal, Non-Separable	[-5,5]	4
F ₃₄	Shekel5	$f(x) = -\sum_{i=1}^5 (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	-10.15	Multimodal, Non-Separable	[0,10]	4
F ₃₅	Shekel7	$f(x) = -\sum_{i=1}^7 (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	-10.40	Multimodal, Non-Separable	[0,10]	4
F ₃₆	Shekel10	$f(x) = -\sum_{i=1}^{10} (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	-10.53	Multimodal, Non-Separable	[0,10]	4
F ₃₇	Perm	$f(x) = \sum_{k=1}^n \left(\sum_{i=1}^n (i^k + \beta) \left(\frac{x_i}{i} \right)^k - 1 \right)^2$	0	Multimodal, Non-Separable	[-D,D]	4
F ₃₈	PowerSum	$f(x) = \sum_{k=1}^n \left(\left(\sum_{i=1}^n x_i^k \right) - b_k \right)^2$	0	Multimodal, Non-Separable	[0,D]	4
F ₃₉	Hartman3	$f(x) = -\sum_{i=1}^4 \exp\left[-\sum_{j=1}^3 a_{ij}(x_j - p_{ij})^2\right]$	-3.86	Multimodal, Non-Separable	[0,1]	3
F ₄₀	Hartman6	$f(x) = -\sum_{i=1}^4 \exp\left[-\sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2\right]$	-3.32	Multimodal, Non-Separable	[0,1]	6
F ₄₁	Griewank	$f(X) = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	0	Multimodal, Non-seperable	[-600, 600]	D
F ₄₂	Ackley	$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i)\right) + 20 + e$	0	Multimodal, Non-seperable	[-35,35]	D

Ek- 3: Test Fonksiyonları ve Özellikleri (F₄₃-F₅₀)

No	Fonksiyon adı	Formül	F _{opt}	Tür	Aralık	D
F ₄₃	Penalized	$f(x) = \frac{\pi}{n} \left\{ 10 \sin^2(\pi y_i) + \sum_{i=1}^{n-1} (y_i - 1)^2 \times [1 + 10 \sin^2(3\pi y_i + 1)] + (y_n - 1)^2 \right\}$	0	Multimodal, Non-seperable	[-50,50]	30
F ₄₄	Penalized2	$f(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^{29} (x_i - 1)^2 p [1 + \sin^2(3\pi x_{i+1})] + (x_n - 1)^2 [1 + \sin^2(2\pi x_{30})] \right\}$	0	Multimodal, Non-seperable	[-50,50]	30
F ₄₅	Langerman2	$f(x) = -c_i \left(\exp\left(\frac{1}{\pi} \sum_{j=1}^n (x_j - a_{ij})^2\right) x \cos\left(\pi \sum_{j=1}^n (x_j - a_{ij})^2\right) \right)$	1.08	Multimodal, Non-seperable	[0,10]	2
F ₄₆	Langerman5	$f(x) = -c_i \left(\exp\left(\frac{1}{\pi} \sum_{j=1}^n (x_j - a_{ij})^2\right) x \cos\left(\pi \sum_{j=1}^n (x_j - a_{ij})^2\right) \right)$	1.5	Multimodal, Non-seperable	[0,10]	5
F ₄₇	Langerman10	$f(x) = -c_i \left(\exp\left(\frac{1}{\pi} \sum_{j=1}^n (x_j - a_{ij})^2\right) x \cos\left(\pi \sum_{j=1}^n (x_j - a_{ij})^2\right) \right)$	-	Multimodal, Non-seperable	[0,10]	10
F ₄₈	FletcherPowell2	$A_i = \sum_{j=1}^n (a_{ij} \sin \alpha_j + b_{ij} \cos \alpha_j)$ $B_i = \sum_{j=1}^n (a_{ij} \sin x_j + b_{ij} \cos x_j)$ $f(x) = \sum_{i=1}^n (A_i - B_i)^2$	0	Multimodal, Non-seperable	$[-\pi, \pi]$	2
F ₄₉	FletcherPowell2	$A_i = \sum_{j=1}^n (a_{ij} \sin \alpha_j + b_{ij} \cos \alpha_j)$ $B_i = \sum_{j=1}^n (a_{ij} \sin x_j + b_{ij} \cos x_j)$ $f(x) = \sum_{i=1}^n (A_i - B_i)^2$	0	Multimodal, Non-seperable	$[-\pi, \pi]$	5
F ₅₀	FletcherPowell10	$A_i = \sum_{j=1}^n (a_{ij} \sin \alpha_j + b_{ij} \cos \alpha_j)$ $B_i = \sum_{j=1}^n (a_{ij} \sin x_j + b_{ij} \cos x_j)$ $f(x) = \sum_{i=1}^n (A_i - B_i)^2$	0	Multimodal, Non-seperable	$[-\pi, \pi]$	10

Ek- 4: Test fonksiyonlarının istatistiksel analizleri (F1-F17)

Fonk.	Indeks	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F1	Avg	-5	-3.5333	8.6333	-5	-5	-5	-5	-5
	Min	-5.0000	-5.0000	3.0000	-5	-5	-5	-5	-5
	Max	-3.0000	6.0000	13.000	-5	-5	-5	-5	-5
	std	0.5683	3.8032	2.9300	0	0	0	0	0
F2	Avg	0	7.07e+03	0	0	5.00e+03	0	9.5000	0
	Min	0	37	0	0	0	0	3.0000	0
	Max	0	20088	0	0	3.00e+3	0	19.0000	0
	std	0	7.49e+03	0	0	7.76e+03	0	4.0322	0
F3	Avg	3.1e-315	2.27e+03	3.81e-56	4.32e-50	3.33e+03	2.0e-128	0.4774	3.5e-190
	Min	0	5.0114	1.1e-199	1.91e-52	7.63e-05	4.3e-150	0.2192	1.3e-194
	Max	5.3e-314	1.20e+04	5.93e-55	2.30e-49	2.00e+04	5.1e-127	0.9875	4.9e-189
	std	0	4.14e+03	1.45e-55	6.15e-50	6.60e+03	9.4e-128	0.1645	0
F4	Avg	4.7e-316	2.05e+03	0	1.42e-50	823.3427	1.6e-132	0.4547	5.9e-191
	Min	0	88.8946	0	4.49e-53	1.38e-05	4.5e-148	0.0564	7.2e-198
	Max	8.9e-315	4.70e+03	0	2.72e-49	3.10e+03	4.7e-131	1.6233	1.4e-189
	std	0	1.24e+03	0	4.92e-50	882.6575	8.6e-132	0.3893	0
F5	Avg	1.01e-04	131.0287	6.35e-05	0.0013	3.5495	0.0029	0.0274	5.07e-04
	Min	4.74e-06	77.1300	1.11e-06	2.75e-04	0.1251	6.82e-05	0.0150	2.04e-04
	Max	3.03e-04	163.0616	1.87e-04	0.0025	19.1157	0.0223	0.0662	8.63e-04
	std	8.27e-05	25.4226	5.81e-05	4.88e-04	4.9027	0.0051	0.0121	1.73e-04
F6	Avg	3.88e-07	0	0.1832	7.51e-08	0.0254	0.0508	0.2032	0
	Min	3.26e-15	0	0.0000	4.99e-09	0	4.92e-15	0.0000	0
	Max	5.02e-06	0	0.6775	4.69e-07	0.7621	0.7621	0.7621	0
	std	9.52e-07	0	0.2941	9.87e-08	0.1391	0.1933	0.3428	0
F7	Avg	-1.0000	-1	-0.1667	-1.0000	-1	-0.9667	-0.9000	-1
	Min	-1.0000	-1	-1.0000	-1.0000	-1	-1.0000	-1.0000	-1
	Max	-1.0000	-1	-0.0001	-1.0000	-1	0	0	-1
	std	1.54e-14	0	0.3790	0.0000	0	0.1826	0.3051	0
F8	Avg	2.2e-319	8.03e-89	0	7.2e-160	1.1e-32	0	1.1e-08	5.5e-271
	Min	0	1.3e-103	0	3.3e-184	4.3e-75	0	1.61e-10	1.8e-289
	Max	5.5e-318	2.40e-87	0	2.1e-158	3.3e-31	9.8e-324	7.6e-08	1.6e-269
	std	0	4.38e-88	0	3.9e-159	6.06e-32	0	1.58e-08	0
F9	Avg	0.0643	1.1500	0.4688	2.4916	1.7948	1.5874	0.0123	5.04e-09
	Min	2.15e-09	1.31e-04	0.0107	0.0001	7.68e-04	0.0083	5.94e-05	9.03e-13
	Max	0.5465	7.8700	3.9235	7.1185	7.8603	8.2480	0.1068	3.87e-08
	std	0.1361	1.9765	0.7203	2.5150	2.3214	2.5747	0.0215	1.06e-08
F10	Avg	-49.8296	-44.4000	18.1345	-49.9999	-50.0000	-49.9996	-49.9999	-50.0000
	Min	-50.0000	-50.0000	13.9631	-50.0000	-50.0000	-50.0000	-50.0000	-50.0000
	Max	-48.7582	118.0000	20.6252	-49.9997	-50.0000	-49.9971	-49.9994	-50.0000
	std	0.3104	30.6725	1.3642	0.0001	4.55e-12	0.0006	1.13e-04	2.08e-13
F11	Avg	-140.402	-34.0448	6.5312	-164.122	90.5697	-209.839	-209.944	-209.953
	Min	-197.878	-210.000	-0.5679	-209.997	-209.998	-209.992	-209.998	-210.000
	Max	-75.4329	1.98e+03	12.6303	-45.0243	3.53e+03	-209.375	-209.567	-209.793
	std	35.2272	508.1316	3.0399	55.9518	810.2896	0.1548	0.1007	0.0444
F12	Avg	1.2e-314	5.6002	52.9450	7.68e-55	16.5318	2.9781	2.91e-04	4.9e-110
	Min	0	3.58e-20	32.1837	9.87e-63	1.47e-14	0.0002	6.76e-05	2.5e-116
	Max	3.7e-313	42.8892	75.6941	2.23e-53	80.2102	16.8227	7.53e-04	1.2e-108
	std	0	12.4044	9.5404	4.06e-54	19.7914	4.3690	1.89e-04	2.2e-109
F13	Avg	1.0e-311	549.5404	0.0244	4.11e-06	687.1879	6.62e-06	0.5944	3.24e-07
	Min	0	8.0892	2.84e-83	5.29e-08	0.0145	1.33e-30	0.1513	1.59e-13
	Max	2.0e-310	5.36e+03	0.6684	2.72e-05	3.78e+03	3.90e-05	1.4422	6.00e-06
	std	0	1.15e+03	0.1218	5.89e-06	1.02e+03	1.07e-05	0.3271	1.10e-06
F14	Avg	1.5e-156	25.1983	0	1.55e-29	33.0007	5.39e-94	0.6146	7.95e-96
	Min	1.1e-175	6.8600	0	2.64e-30	4.31e-04	3.7e-108	0.2394	1.10e-97
	Max	4.6e-155	45.1777	0	5.80e-29	110.0000	1.38e-92	1.3122	7.58e-95
	std	8.5e-156	11.2633	0	1.44e-29	25.0718	2.54e-93	0.2457	1.51e-95
F15	Avg	2.6e-319	2.03e+04	0.0031	1.69e-09	1.79e+04	2.99e+04	88.8993	5.36e-44
	Min	0	4.45e+03	0.0000	1.30e-16	1.47e+03	4.64e+03	36.8332	2.95e-51
	Max	6.6e-318	4.07e+04	0.0199	3.52e-08	4.17e+04	5.57e+04	165.7206	1.47e-42
	std	0	8.56e+03	0.0057	6.82e-09	1.15e+04	1.14e+04	37.7064	2.68e-43
F16	Avg	28.7223	1.55e+06	28.3168	26.9678	2.68e+06	27.7933	206.5566	25.5933
	Min	28.6993	1.73e+04	27.2311	25.3052	11.7659	26.7619	29.6640	24.7906
	Max	28.7661	5.45e+06	28.8167	28.7650	8.00e+07	28.7783	1.61e+03	26.1739
	std	0.0147	1.61e+06	0.3814	0.8987	1.46e+07	0.6644	335.3382	0.3127
F17	Avg	0.9665	1.05e+04	0.6667	0.6667	4.93e+04	0.6668	3.0067	0.6667
	Min	0.8550	253.0600	0.6667	0.6667	0.0423	0.6667	0.7225	0.6667
	Max	0.9923	8.86e+04	0.6667	0.6667	3.91e+05	0.6670	17.4054	0.6667
	std	0.0330	1.73e+04	0.0000	1.23e-06	9.17e+04	1.11e-04	4.0463	4.32e-12

Ek- 5: Test fonksiyonlarının istatistiksel analizleri (F₁₈-F₃₄)

Fonk.	Indeks	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F18	Avg	2.0496	3.1665	7.6813	5.1662	4.2444	2.9997	0.9980	0.9980
	Min	0.9980	0.9980	0.9980	0.9980	0.9980	0.9980	0.9980	0.9980
	Max	12.6705	9.8039	12.6705	12.6705	20.1535	10.7632	0.9980	0.9980
	std	3.1209	2.5963	4.8188	4.8147	5.1031	2.7911	1.09e-11	0
F19	Avg	0.3981	0.4494	0.4011	0.3979	0.3979	0.3979	0.3979	0.3979
	Min	0.3979	0.3979	0.3980	0.3979	0.3979	0.3979	0.3979	0.3979
	Max	0.3989	1.9431	0.4085	0.3979	0.3979	0.3979	0.3979	0.3979
	std	2.51e-04	0.2821	0.0027	8.87e-07	0	3.87e-06	2.98e-07	0
F20	Avg	0	0	0	0	0	0	1.93e-04	0
	Min	0	0	0	0	0	0	1.06e-05	0
	Max	0	0	0	0	0	0	5.97e-04	0
	std	0	0	0	0	0	0	1.45e-04	0
F21	Avg	1.07e-14	0	4.73e-07	2.63e-07	0	5.49e-04	2.68e-07	0
	Min	2.52e-27	0	1.87e-08	7.26e-11	0	1.08e-05	2.08e-09	0
	Max	2.47e-13	0	1.93e-06	1.13e-06	0	0.0017	1.04e-06	0
	std	4.54e-14	0	4.93e-07	2.87e-07	0	5.02e-04	2.44e-07	0
F22	Avg	0	171.5601	0	0.6800	180.4420	1.89e-15	118.6773	14.1645
	Min	0	103.9156	0	0	98.5005	0	63.9350	1.5721
	Max	0	283.1658	0	8.8993	259.8960	5.68e-14	210.2284	33.0903
	std	0	43.6998	0	1.9056	35.6430	1.03e-14	37.9570	6.2158
F23	Avg	-4.4e+03	-6.9e+03	-6707.6	-5.9e+03	-8.3e+03	-1.0e+04	-7.9e+03	-7.7e+03
	Min	-5.2e+03	-9.4e+03	-8202.2	-7.8e+03	-9.7e+03	-1.2e+04	-9.3e+03	-8.7e+03
	Max	-3.8e+03	-5.0e+03	-5898.7	-3.2e+03	-6.4e+03	-6.5e+03	-6.7e+03	-6.6e+03
	std	365.4246	1.12e+03	447.2	882.6682	843.1291	1.91e+03	671.8932	538.4442
F24	Avg	-1.8013	-1.8013	-1.7945	-1.7746	-1.8013	-1.8013	-1.8013	-1.8013
	Min	-1.8013	-1.8013	-1.8007	-1.8013	-1.8013	-1.8013	-1.8013	-1.8013
	Max	-1.8013	-1.8013	-1.7724	-1.0000	-1.8013	-1.8013	-1.8013	-1.8013
	std	6.23e-09	9.19e-16	0.0062	0.1463	9.03e-16	1.17e-06	2.28e-07	9.03e-16
F25	Avg	-4.2681	-4.1985	-3.2513	-4.1501	-4.2334	-3.5471	-3.9627	-4.5370
	Min	-4.6877	-4.6877	-3.8107	-4.6876	-4.6877	-4.4949	-4.6459	-4.6877
	Max	-3.8731	-2.7773	-2.6082	-2.8446	-3.3749	-2.2982	-3.2902	-3.8446
	std	0.1489	0.4875	0.2774	0.5130	0.3974	0.6365	0.4495	0.1509
F26	Avg	-6.0300	-7.5340	-4.5775	-7.5681	-7.7196	-5.7288	-6.9424	-8.9293
	Min	-7.0597	-9.1715	-5.7824	-9.2981	-9.3834	-7.8537	-8.3165	-9.6135
	Max	-5.3617	-4.0719	-3.7992	-5.8670	-3.9069	-3.5932	-5.1014	-7.2023
	std	0.4033	1.0869	0.4405	0.8355	1.1696	0.8569	0.9248	0.4817
F27	Avg	0	0	0	0	0.0007	0	1.41e-08	0
	Min	0	0	0	0	0	0	3.98e-10	0
	Max	0	0	0	0	0.0094	0	5.38e-08	0
	std	0	0	0	0	0.0020	0	1.47e-08	0
F28	Avg	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316
	Min	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316
	Max	-1.0315	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316	-1.0316
	std	1.50e-05	6.25e-16	1.04e-07	9.17e-09	6.77e-16	3.75e-10	1.51e-07	6.71e-16
F29	Avg	0	0	0	0	0	0	2.03e-04	0
	Min	0	0	0	0	0	0	7.36e-06	0
	Max	0	0	0	0	0	0	5.86e-04	0
	std	0	0	0	0	0	0	1.82e-04	0
F30	Avg	0	0	0	0	0	7.06e-16	6.39e-05	0
	Min	0	0	0	0	0	0	5.01e-07	0
	Max	0	0	0	0	0	5.16e-15	2.91e-04	0
	std	0	0	0	0	0	1.11e-15	6.98e-05	0
F31	Avg	-186.730	-186.730	-148.411	-186.713	-186.730	-186.730	-186.730	-186.730
	Min	-186.730	-186.730	-186.730	-186.730	-186.730	-186.730	-186.730	-186.730
	Max	-186.265	-186.730	-64.4039	-186.509	-186.730	-186.725	-186.729	-186.730
	std	0.1161	9.20e-14	43.9930	0.0564	3.42e-14	0.0012	2.88e-04	5.70e-14
F32	Avg	3.0000	8.4000	6.1828	5.7000	3.0000	3.0000	5.7000	3.0000
	Min	3.0000	3.0000	3.0000	3.0000	3.0000	3.0000	3.0000	3.0000
	Max	3.0000	84.0000	52.3316	84.0000	3.0000	3.0006	84.0000	3.0000
	std	3.92e-12	20.5504	10.2223	14.7885	1.97e-15	0.0001	14.7885	5.53e-16
F33	Avg	3.25e-04	0.0032	0.0108	0.0044	0.0029	0.0007	0.0078	3.24e-04
	Min	3.07e-04	0.0003	0.0003	0.0003	0.0006	0.0003	0.0003	3.07e-04
	Max	5.11e-04	0.0204	0.0983	0.0204	0.0204	0.0030	0.0204	8.11e-04
	std	4.13e-05	0.0060	0.0223	0.0081	0.0051	0.0006	0.0094	9.19e-05
F34	Avg	-10.1092	-5.8020	-4.8968	-8.9014	-5.2979	-8.8752	-7.7191	-9.5343
	Min	-10.1532	-10.1532	-8.6498	-10.1531	-10.1532	-10.1531	-10.1532	-10.1532
	Max	-9.9756	-2.6305	-3.0341	-3.0653	-2.6305	-2.6299	-2.6305	-2.6305
	std	0.0518	3.0765	1.3241	2.3326	2.9285	2.6183	3.1296	1.7678

Ek- 6: Test fonksiyonlarının istatistiksel analizleri (F₃₄-F₅₀)

Fonk.	Indeks	PS-VTS	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F35	Avg	-10.2468	-6.4679	-5.4107	-10.4023	-6.8348	-7.9980	-8.0523	-9.6712
	Min	-10.4029	-10.4029	-8.4493	-10.4029	-10.4029	-10.5358	-10.4029	-10.4029
	Max	-9.5082	-1.8376	-3.4310	-10.4013	-2.7519	-1.6738	-2.7519	-4.3973
	std	0.2387	3.6121	1.4997	0.0004	3.4617	3.0047	3.0005	1.9007
F36	Avg	-10.5359	-5.5773	-5.3862	-10.5359	-7.8874	-7.5377	-8.5822	-10.3216
	Min	-10.5364	-10.5364	-8.0426	-10.5363	-10.5364	-10.5356	-10.5364	-10.5364
	Max	-8.2170	-1.8595	-2.3074	-10.5352	-2.4217	-2.4262	-2.4273	-4.0925
	std	0.6867	3.6336	1.2916	0.002	3.3614	3.3260	3.1165	1.1765
F37	Avg	3.1350	30.1130	75.7100	2.0926	0.2935	12.2489	0.0941	0.0251
	Min	0.4450	0.0014	1.9080	0.0028	1.31e-04	0.0746	1.89e-04	1.47e-05
	Max	8.2511	895.5317	511.1259	11.2273	2.4321	221.4849	0.4729	0.4537
	std	2.0273	163.4523	128.7612	2.4556	0.6018	40.2212	0.1594	0.0831
F38	Avg	0.0352	0.0153	0.1602	0.3336	0.0734	4.1071	0.0010	0.0003
	Min	0.0033	0.0002	0.0068	2.26e-04	1.05e-05	0.0391	3.19e-05	1.15e-07
	Max	0.1206	0.0878	0.6145	0.8864	0.8875	21.1317	0.0045	0.0029
	std	0.0286	0.0226	0.1426	0.3793	0.2218	5.6754	0.0013	0.0005
F39	Avg	-3.8628	-3.8628	-3.8552	-3.8613	-3.8628	-3.8565	-3.8628	-3.8628
	Min	-3.8628	-3.8628	-3.8621	-3.8628	-3.8628	-3.8628	-3.8628	-3.8628
	Max	-3.8628	-3.8628	-3.8491	-3.8549	-3.8628	-3.8171	-3.8628	-3.8628
	std	3.16e-08	2.62e-15	0.0027	0.0026	2.71e-15	0.0104	8.11e-07	2.69e-15
F40	Avg	-3.3094	-3.1812	-3.1406	-3.2592	-3.2194	-3.2359	-3.2619	-3.3092
	Min	-3.3220	-3.3220	-3.2476	-3.3220	-3.3220	-3.3219	-3.3220	-3.3220
	Max	-3.2550	-1.7061	-3.0079	-3.0784	-3.1345	-2.8397	-3.1998	-3.2031
	std	0.0183	0.2884	0.0540	0.0832	0.0624	0.1208	0.0611	0.0340
F41	Avg	0	30.3606	0.1572	0.0055	21.0908	0.0065	0.7050	0
	Min	0	3.3841	0.0167	0	0.0001	0	0.5337	0
	Max	0	134.2443	0.3711	0.0361	180.0915	0.1103	0.8772	0
	std	0	35.8234	0.0973	0.0106	45.3859	0.0250	0.0940	0
F42	Avg	8.88e-16	13.5760	8.88e-16	2.10e-14	16.9355	3.84e-15	1.5304	6.21e-15
	Min	8.88e-16	8.4883	8.88e-16	1.50e-14	2.2201	8.88e-16	0.2018	4.44e-15
	Max	8.88e-16	20.6453	8.88e-16	2.93e-14	19.9627	7.99e-15	3.4260	7.99e-15
	std	0	3.3273	0	3.88e-15	5.4583	2.30e-15	0.7873	1.80e-15
F43	Avg	0.0349	3.16e+05	0.4712	0.0563	3.43e+03	0.0323	1.8216	0.0104
	Min	0.0110	12.1928	0.3896	0.0202	6.40e-04	0.0032	0.0401	7.58e-11
	Max	0.1719	4.12e+06	0.5734	0.1118	1.03e+05	0.4687	5.1553	0.1037
	std	0.0333	8.64e+05	0.0472	0.0229	1.88e+04	0.0830	1.1358	0.0316
F44	Avg	0.3807	8.51e+04	2.8030	0.6971	43.0455	0.5046	0.1175	0.0792
	Min	0.1624	58.2666	2.6257	0.2222	0.0320	0.0872	0.0418	5.05e-08
	Max	1.3960	9.39e+05	2.9619	1.1336	530.3682	1.4896	0.2949	0.2932
	std	0.2638	2.10e+05	0.0836	0.2487	110.7600	0.3087	0.0591	0.0744
F45	Avg	-1.0809	-1.0759	-1.0790	-1.0809	-1.0734	-1.0764	-1.0809	-1.0809
	Min	-1.0809	-1.0809	-1.0809	-1.0809	-1.0809	-1.0809	-1.0809	-1.0809
	Max	-1.0809	-1.0053	-1.0738	-1.0809	-1.0053	-0.9456	-1.0809	-1.0809
	std	1.32e-06	0.0192	0.0019	2.27e-07	0.0231	0.0247	3.73e-07	4.51e-16
F46	Avg	-1.3996	-0.8585	-0.9043	-1.0598	-0.8202	-0.6155	-1.2173	-1.1506
	Min	-1.5000	-1.5000	-1.3465	-1.5000	-1.5000	-0.9175	-1.5000	-1.5000
	Max	-1.0119	-0.2233	-0.5276	-0.5056	-0.4502	-0.1352	-0.9080	-0.4829
	std	0.1390	0.3677	0.2032	0.3181	0.3430	0.1873	0.2878	0.3810
F47	Avg	-0.5679	-0.2951	-0.2909	-0.4483	-0.3699	-0.1808	-0.5258	-0.4100
	Min	-0.7977	-0.7977	-0.5352	-0.7977	-0.7977	-0.4829	-0.8760	-0.7977
	Max	-0.2447	-0.0215	-0.0800	-0.1455	-0.0199	-0.0279	-0.2749	-0.1181
	std	0.2151	0.1732	0.1098	0.2312	0.2370	0.1262	0.1765	0.1882
F48	Avg	0.0051	23.5098	3.13e-05	23.5187	0	2.09e-07	90.3130	0
	Min	5.47e-06	0	1.31e-07	3.05e-05	0	7.85e-11	5.18e-07	0
	Max	0.0189	705.2950	1.87e-04	705.2950	0	1.30e-06	1.29e+03	0
	std	0.0053	128.7687	3.61e-05	128.7670	0	3.85e-07	289.8909	0
F49	Avg	31.3898	939.7024	8.13e+03	188.1204	220.2955	375.8342	374.3277	33.6348
	Min	4.59e-04	9.4437	0.0172	0.0708	5.65e-26	0.4913	0.0017	2.01e-28
	Max	130.8601	3.55e+03	4.38e+04	1.50e+03	2.07e+03	2.28e+03	3.60e+03	185.9625
	std	34.7920	1.26e+03	1.02e+04	277.8448	453.8911	706.5158	823.0286	69.7259
F50	Avg	1.06e+04	1.23e+04	1.31e+05	4.78e+03	4.51e+03	1.33e+04	2.96e+03	2.09e+03
	Min	555.7501	9.4277	3.22e+04	108.1057	196.4413	300.4677	1.8504	0.1457
	Max	2.41e+04	7.85e+04	2.17e+05	2.96e+04	1.10e+04	4.47e+04	3.34e+04	1.47e+04
	std	6.53e+03	2.21e+04	4.66e+04	6.64e+03	3.51e+03	1.38e+04	6.59e+03	3.21e+03

Ek- 7: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F1-F11)

Fonk.	Boyut	İndeks	IPSO	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F1	D=10	Avg	-2.3333	-5	8.3333	-4.6667	-5	-5	-5	-5
		Std	0.6609	0	2.4960	1.2685	0	0	0	0
	D=50	Avg	-2.5000	-5	9.5333	-4.8333	-5	-5	-5	-5
		Std	0.5724	0	2.0965	0.9129	0	0	0	0
F2	D=100	Avg	-2.4000	-5	8.2000	-4.8333	-5	-5	-5	-5
		Std	0.5632	0	2.8089	0.9129	0	0	0	0
	D=10	Avg	0	9.7667	0	0	0	0.0333	0.7000	0
		Std	0	19.6006	0	0	0	0.1826	0.8367	0
F3	D=50	Avg	0	1.72e+04	0	0	8.4470	0.0333	35.4333	0
		Std	0	6.57e+03	0	0	6.7275	0.1826	12.4670	0
	D=100	Avg	0	7.11e+04	0	0	4.53e+04	0.0333	256.8667	0
		Std	0	1.12e+04	0	0	1.67e+04	0.1826	56.4524	0
F4	D=10	Avg	1.3e-296	1.22e-07	0	1.01e-96	4.24e-28	0.0733	0.0061	0.5876
		Std	0	6.72e-07	0	3.07e-96	1.08e-27	0.4008	0.0032	0
	D=50	Avg	4.0e-280	1.57e+04	1.94e-04	3.75e-37	6.6944	7.8e-127	3.8839	7.7e-183
		Std	0	6.46e+03	6.08e-04	8.64e-37	7.5064	3.0e-126	1.2619	0
F5	D=100	Avg	1.1e-275	6.77e+04	0.0211	2.10e-25	3.69e+04	6.2e-125	63.9135	7.3e-176
		Std	0	1.34e+04	0.0093	2.31e-25	1.44e+04	3.4e-124	10.8436	0
	D=10	Avg	1.1e-290	3.3333	0	2.26e-99	1.28e-29	0.1385	7.11e-04	0.1751
		Std	0	18.2574	0	8.05e-99	3.31e-29	0.7585	8.96e-04	0
F6	D=50	Avg	2.9e-290	3.81e+03	0	6.34e-38	2.76e+03	2.3e-128	10.5261	3.7e-183
		Std	0	1.43e+03	0	8.50e-38	2.38e+03	1.0e-127	9.1887	0
	D=100	Avg	2.1e-289	3.21e+04	5.4e-104	8.79e-26	1.92e+04	1.9e-125	167.7989	1.3e-176
		Std	0	6.79e+03	2.9e-103	1.02e-25	8.42e+03	9.8e-125	64.5524	0
F7	D=10	Avg	3.70e-04	0.0235	5.33e-04	5.20e-04	0.0135	0.0015	0.0026	0.3865
		Std	3.56e-04	0.0173	6.00e-04	3.20e-04	0.0114	0.0021	0.0018	0.1854
	D=50	Avg	3.66e-04	19.9504	4.96e-04	0.0020	23.1602	0.0028	0.0875	6.37e-04
		Std	3.60e-04	10.7591	5.08e-04	0.0012	22.6582	0.0025	0.0277	2.04e-04
F8	D=100	Avg	3.89e-04	215.7756	4.83e-04	0.0039	228.8346	0.0030	0.4554	7.73e-04
		Std	3.82e-04	69.3645	3.91e-04	0.0013	161.9823	0.0032	0.1043	2.84e-04
	D=10	Avg	4.77e-17	0.1524	0.2237	0.0762	2.78e-12	0.0762	0.2032	0
		Std	2.45e-16	0.3100	0.3150	0.2325	1.21e-18	0.2325	0.3428	0
F9	D=50	Avg	2.26e-16	0.0254	0.0897	0.0762	4.09e-10	0.0254	0.0254	0
		Std	9.22e-16	0.1391	0.2318	0.2325	2.24e-09	0.1391	0.1391	0
	D=100	Avg	0.0508	0.0508	0.1423	0.0762	5.96e-19	0.1016	0.1778	0.0254
		Std	0.1933	0.1933	0.3465	0.2325	2.63e-18	0.2635	0.3278	0.1391
F10	D=10	Avg	-1	-0.9667	-0.1667	-1	-1	-1	-0.7667	-1
		Std	5.31e-13	0.1826	0.3790	2.98e-07	0	2.25e-05	0.4302	0
	D=50	Avg	-1	-1	-0.0667	-1	-1	-1	-0.7667	-1
		Std	7.60e-15	0	0.2537	3.36e-07	0	6.59e-07	0.4302	0
F11	D=100	Avg	-1	-1	-0.1692	-1	-1	-1	-0.8666	-1
		Std	1.46e-14	0	0.3781	3.16e-07	0	9.25e-07	0.3457	0
	D=10	Avg	7.9e-299	1.93e-91	0	1.2e-165	1.85e-27	0	1.38e-08	0.3711
		Std	0	7.66e-91	0	0	1.00e-26	0	1.55e-08	0
F12	D=50	Avg	2.1e-286	9.33e-88	0	4.0e-156	9.17e-24	0	1.31e-08	3.8e-272
		Std	0	5.09e-87	0	2.1e-155	4.60e-23	0	1.50e-08	0
	D=100	Avg	1.6e-289	6.80e-89	0	2.1e-161	1.03e-31	0	1.21e-08	5.9e-271
		Std	0	3.72e-88	0	1.0e-160	5.68e-31	0	1.37e-08	0
F13	D=10	Avg	0.5163	0.6118	0.4107	1.7882	1.1481	1.1174	0.0288	2.28e-08
		Std	0.8427	1.2964	0.2929	2.2618	1.6452	1.5756	0.0361	7.09e-08
	D=50	Avg	0.6659	0.5901	0.5392	2.3383	1.4443	1.4550	0.2809	2.25e-09
		Std	1.0807	1.4361	0.6075	2.5790	2.0132	2.3931	1.4325	1.02e-08
F14	D=100	Avg	0.7388	0.6205	0.6441	1.5464	1.4387	1.9652	0.0945	7.11e-09
		Std	1.1869	1.3116	0.9473	2.0716	2.0454	2.4146	0.3795	1.85e-08
	D=10	Avg	-34.7300	-50	-25.4844	-49.2987	-41.1000	-49.9997	-49.9999	-50.0000
		Std	9.8948	1.78e-12	5.1730	3.8403	48.7473	3.25e-04	9.32e-05	2.56e-13
F15	D=50	Avg	-30.7602	-44.4000	-26.4680	-49.9998	-50	-49.9997	-49.9998	-50.0000
		Std	10.5854	30.6725	4.8359	8.88e-05	2.15e-11	3.53e-04	1.29e-04	1.54e-13
	D=100	Avg	-32.7500	-35.4999	-27.4154	-49.9999	-43.6000	-49.9996	-49.9999	-50.0000
		Std	9.5395	56.6920	3.4636	1.04e-04	35.0542	4.00e-04	1.25e-04	1.13e-13
F16	D=10	Avg	-70.0894	13.1355	-33.4225	-164.627	67.4598	-209.870	-209.969	-209.952
		Std	30.7333	742.3823	5.0589	55.1747	523.8394	0.1802	0.0311	0.0445
	D=50	Avg	-74.7791	-155.314	-32.7910	-146.365	-209.723	-209.856	-209.957	-209.967
		Std	33.5064	240.7727	5.3491	63.6424	0.3335	0.1384	0.0438	0.0423
F17	D=100	Avg	-67.5101	-184.395	-36.7645	-177.739	130.3926	-209.816	-209.961	-209.960
		Std	25.6536	70.1154	9.2187	50.1468	592.3856	0.1675	0.0511	0.0468

Ek- 8: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F12-F21)

Fonk.	Boyut	İndeks	IPSO	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F12	D=10	Avg	1.4e-296	13.1303	1.00e-06	3.55e-56	35.0192	4.3319	3.59e-04	3.7e-109
		Std	0	29.4169	5.48e-06	1.21e-55	38.2265	5.0470	2.55e-04	1.7e-108
	D=50	Avg	2.3e-288	8.6259	2.27e-07	9.95e-57	23.9583	7.3461	2.90e-04	1.0e-108
		Std	0	20.8923	1.00e-06	3.20e-56	26.4745	13.6225	1.48e-04	5.6e-108
F13	D=100	Avg	5.6e-286	2.2053	1.81e-05	7.86e-57	20.8409	2.7743	3.29e-04	2.9e-110
		Std	0	5.5525	9.84e-05	2.73e-56	30.2921	4.0925	1.69e-04	1.2e-109
	D=10	Avg	3.9e-290	558.2056	0.0013	3.29e-06	988.3778	3.48e-06	0.4527	2.11e-07
		Std	0	984.8962	0.0064	2.83e-06	1.37e+03	1.29e-05	0.2700	4.46e-07
F14	D=50	Avg	4.4e-287	393.0426	0.0414	3.49e-06	694.3744	6.91e-06	0.4301	2.43e-07
		Std	0	823.1159	0.1625	4.48e-06	1.00e+03	1.82e-05	0.1915	6.19e-07
	D=100	Avg	1.6e-294	513.0564	0.0034	3.16e-06	637.9918	4.29e-06	0.4890	2.17e-07
		Std	0	914.4187	0.0117	3.90e-06	835.2626	1.25e-05	0.2542	5.20e-07
F15	D=10	Avg	4.0e-146	0.4963	0	2.42e-56	2.3333	4.22e-97	0.0241	1.1e-114
		Std	2.2e-145	1.9385	0	3.76e-56	4.3018	2.29e-96	0.0078	2.0e-114
	D=50	Avg	3.2e-146	73.9335	3.4e-259	2.34e-22	53.8982	4.90e-94	4.28e+04	1.89e-92
		Std	1.7e-145	22.5755	0	2.53e-22	26.2740	2.63e-93	2.34e+05	3.32e-92
F16	D=100	Avg	9.5e-145	9.37e+09	8.05e-87	1.27e-15	181.9600	9.46e-94	2.59e+21	9.14e-90
		Std	5.0e-144	5.13e+10	4.35e-86	8.21e-16	45.2704	3.89e-93	1.42e+22	9.33e-90
	D=10	Avg	1.9e-283	208.6702	1.2e-119	8.67e-43	888.8890	49.5760	0.0524	1.2e-101
		Std	0	912.0898	6.6e-119	2.43e-42	2.04e+03	85.8743	0.0448	5.2e-101
F17	D=50	Avg	2.8e-284	6.25e+04	0.0748	0.0010	5.57e+04	1.84e+05	3.18e+03	9.29e-31
		Std	0	1.79e+04	0.1255	0.0022	2.19e+04	3.65e+04	998.8557	4.35e-30
	D=100	Avg	1.9e-308	2.32e+05	0.7069	29.3191	2.21e+05	1.00e+06	5.47e+04	9.29e-21
		Std	0	4.49e+04	0.4713	35.1778	5.97e+04	2.08e+05	6.46e+03	4.43e-20
F18	D=10	Avg	8.9242	3.15e+03	6.2812	6.7193	6.26e+03	6.7124	118.2874	3.2970
		Std	0.0260	1.64e+04	0.2954	0.5445	2.27e+04	0.8250	340.9739	0.8030
	D=50	Avg	48.6082	1.43e+07	48.6746	47.1933	1.38e+07	47.8230	793.9512	46.2593
		Std	0.0893	7.78e+06	0.2040	0.7775	3.67e+07	0.4831	826.3983	0.6146
F19	D=100	Avg	98.1460	1.26e+08	98.8237	97.9336	1.10e+08	97.9760	3.99e+03	96.8729
		Std	0.0369	4.23e+07	0.1542	0.5477	7.07e+07	0.4197	3.11e+03	0.8308
	D=10	Avg	0.8952	1.0442	0.6667	0.6667	20.0810	0.6526	0.6046	0.6667
		Std	0.0552	3.0222	3.62e-09	8.56e-05	36.4546	0.1282	0.1955	6.33e-16
F20	D=50	Avg	0.9968	2.63e+05	0.6667	0.6667	1.65e+05	0.6667	18.9904	0.6667
		Std	0.0021	1.91e+05	3.85e-07	1.01e-05	2.78e+05	1.03e-04	18.3362	6.08e-09
	D=100	Avg	0.9978	2.65e+06	0.6667	0.6667	3.15e+06	0.6669	166.1779	0.6667
		Std	0.0009	8.02e+05	3.99e-05	4.12e-05	2.16e+06	1.83e-04	83.2397	1.47e-09
F21	D = 10	Avg	5.1993	3.6791	9.7207	4.3958	3.1381	4.7492	0.9980	0.9980
		Std	5.1203	3.6644	4.0575	3.9914	2.0978	4.3943	8.01e-12	0
	D=50	Avg	5.9710	4.3872	7.3392	5.7226	3.5554	3.5744	0.9980	0.9980
		Std	5.5107	4.4955	4.3072	4.7040	3.0977	4.0817	2.18e-11	0
F22	D=100	Avg	1.0989	4.6187	8.0198	4.0370	2.7974	3.1218	0.9980	0.9980
		Std	0.3992	4.3601	4.7820	3.8813	3.1819	3.5626	1.15e-11	0
	D=10	Avg	0.3979	0.4494	0.4011	1.82e-06	0.3979	0.3979	0.3979	0.3979
		Std	3.9e-05	0.2821	0.0028	0.3979	0	1.46e-05	2.46e-07	0
F23	D=50	Avg	0.3979	0.4494	0.4016	0.3979	0.3979	0.3979	0.3979	0.3979
		Std	3.29e-05	0.2821	0.0024	1.10e-06	0	3.62e-06	1.46e-07	0
	D=100	Avg	0.3979	0.3979	0.4018	0.3979	0.3979	0.3979	0.3979	0.3979
		Std	2.17e-04	0	0.0037	1.41e-04	0	5.19e-06	3.35e-07	0
F24	D=10	Avg	0	0	0	0	0	0	2.21e-04	0
		Std	0	0	0	0	0	0	1.74e-04	0
	D=50	Avg	0	0	0	0	0	0	1.94e-04	0
		Std	0	0	0	0	0	0	1.84e-04	0
F25	D=100	Avg	0	0	0	0	0	0	2.13e-04	0
		Std	0	0	0	0	0	0	1.73e-04	0
	D=10	Avg	1.85e-08	0	4.90e-07	1.75e-07	0	4.20e-04	2.55e-07	0
		Std	3.68e-08	0	4.62e-07	1.31e-07	0	8.02e-04	1.99e-07	0
F26	D =50	Avg	1.31e-08	0	3.50e-07	2.06e-07	0	0.0008	3.07e-07	0
		Std	2.60e-08	0	3.47e-07	1.78e-07	0	0.0010	3.37e-07	0
	D=100	Avg	1.95e-08	0	3.99e-07	1.68e-07	0	0.0010	3.14e-07	0
		Std	3.52e-08	0	4.10e-07	1.41e-07	0	0.0014	3.58e-07	0

Ek- 9: Ölçülebilirlik Analizleri için İstatistiksel Sonuçlar (F21-F25)

Fonk.	Boyut	İndeks	IPSO	PSO	AOA	GWO	MFO	WOA	MVO	TLBO
F22	D =10	Avg	0	24.6983	0	0.1390	27.8374	1.0702	13.7340	2.8150
		Std	0	12.2150	0	0.7615	14.2236	5.8615	5.7625	2.2358
	D = 50	Avg	0	375.1769	0	1.4881	337.1644	0	241.9643	19.1591
		Std	0	66.6017	0	3.2193	63.3558	0	43.5466	22.3274
	D=100	Avg	0	948.2253	0	1.4848	789.5306	3.78e-15	653.0561	5.5207
		Std	0	103.6840	0	3.1858	58.4415	2.07e-14	65.9137	30.2383
F23	D =10	Avg	-2.5e+03	-3.1e+03	-3.9e+03	-2.6e+03	-3.3e+03	-3.5e+03	-2.9e+03	-3.4e+03
		Std	158.2583	426.9692	147.8735	338.2298	333.8527	583.9779	325.5285	273.7657
	D =50	Avg	-5.8e+03	-1.1e+04	-8.1e+03	-8.7e+03	-1.3e+04	-1.7e+04	-1.2e+04	-1.2e+04
		Std	413.0177	1.63e+03	-1.1e+04	1.50e+03	1.77e+03	3.14e+03	928.4356	1.13e+03
	D=100	Avg	-8.1e+03	-1.6e+04	593.0749	-1.6e+04	-2.3e+04	-3.7e+04	-2.4e+04	-2.0e+04
		Std	526.2818	2.99e+03	696.1978	3.13e+03	2.24e+03	5.64e+03	1.52e+03	3.29e+03
F24	D = 10	Avg	-1.8013	-1.7746	-1.7935	-1.8013	-1.8013	-1.7479	-1.7746	-1.8013
		Std	1.91e-08	0.1463	0.0079	1.66e-06	9.03e-16	0.2033	0.1463	9.03e-16
	D = 50	Avg	-1.8013	-1.7746	-1.7943	-1.7746	-1.8013	-1.7746	-1.8013	-1.8013
		Std	2.72e-08	0.1463	0.0060	0.1463	9.03e-16	0.1463	3.49e-07	9.03e-16
	D=100	Avg	-1.8013	-1.7817	-1.7958	-1.7746	-1.8013	-1.7479	-1.7746	-1.8013
		Std	3.26e-08	0.1072	0.0039	0.1463	9.03e-16	0.2033	0.1463	9.03e-16
F25	D = 10	Avg	-3.6970	-4.3171	-3.3180	-4.3498	-4.4160	-3.4907	-3.9674	-4.5720
		Std	0.2948	0.4314	0.3025	0.4685	0.2741	0.5416	0.6366	0.0774
	D = 50	Avg	-3.6319	-4.2781	-3.3130	-4.2289	-4.4114	-3.7487	-3.9331	-4.5849
		Std	0.2258	0.3353	0.3120	0.5014	0.2605	0.6431	0.5849	0.0914
	D=100	Avg	-3.6354	-4.2311	-3.3863	-4.3154	-4.2564	-3.6108	-4.1058	-4.5543
		Std	0.2047	0.4594	0.3419	0.4272	0.3828	0.5729	0.4528	0.1646

Ek- 10: Önerilen Co-GoldSa Yöntemi ile Göğüs kanseri görüntülerinden elde edilen SSIM değerleri

Test Image 1						
	4	6	8	12	16	20
MVO (2015)	0.0724	0.0685	0.1022	0.0904	0.0853	0.0626
MFO (2015)	0.0356	0.0428	0.1167	0.1981	0.0558	0.1157
WOA (2016)	0.0356	0.0678	0.1333	0.1029	0.0889	0.091
AOA (2021)	0.608	0.6882	0.7483	0.7791	0.7518	0.7816
AO (2021)	0.5409	0.5409	0.6886	0.8163	0.8393	0.852
CO (2022)	0.5817	0.7518	0.7482	0.8197	0.8369	0.8364
RSA (2022)	0.5409	0.7444	0.6007	0.7959	0.8461	0.8533
SAO (2023)	0.5766	0.6961	0.6961	0.8168	0.8368	0.8273
Co-GoldSa	0.6792	0.6970	0.7989	0.8284	0.8536	0.8583
Test Image 2						
MVO (2015)	0.2473	0.2306	0.3068	0.5459	0.6797	0.5807
MFO (2015)	0.1943	0.2306	0.4077	0.4127	0.2486	0.5213
WOA (2016)	0.2473	0.2345	0.4146	0.4169	0.5201	0.4979
AOA (2021)	0.5758	0.6337	0.7784	0.8851	0.9109	0.9349
AO (2021)	0.6094	0.6094	0.8210	0.8772	0.9141	0.8812
CO (2022)	0.5585	0.6635	0.7829	0.8569	0.8892	0.9252
RSA (2022)	0.6181	0.6068	0.7998	0.8796	0.8755	0.9441
SAO (2023)	0.6094	0.7487	0.8210	0.9066	0.9288	0.9352
Co-GoldSa	0.6194	0.7647	0.8210	0.8903	0.9207	0.9491
Test Image 3						
MVO (2015)	0.1067	0.5053	0.3315	0.5607	0.6215	0.6958
MFO (2015)	0.0458	0.6941	0.3151	0.289	0.6416	0.5473
WOA (2016)	0.1067	0.3276	0.5461	0.4627	0.5854	0.6119
AOA (2021)	0.6518	0.7606	0.8043	0.8727	0.8694	0.9202
AO (2021)	0.6824	0.6824	0.8296	0.9008	0.9250	0.9327
CO (2022)	0.6595	0.7634	0.7923	0.8599	0.8858	0.9173
RSA (2022)	0.6823	0.7813	0.8258	0.8833	0.9125	0.9251
SAO (2023)	0.6824	0.7813	0.8296	0.9012	0.9244	0.9381
Co-GoldSa	0.6824	0.7878	0.8296	0.9057	0.9250	0.9319
Test Image 4						
MVO (2015)	0.6326	0.0576	0.7096	0.3644	0.4907	0.7578
MFO (2015)	0.6131	0.4781	0.743	0.1627	0.5134	0.5738
WOA (2016)	0.6326	0.352	0.578	0.4695	0.4726	0.4373
AOA (2021)	0.672	0.714	0.6982	0.8541	0.9234	0.8693
AO (2021)	0.6852	0.6852	0.8391	0.8908	0.9361	0.9438
CO (2022)	0.681	0.783	0.8101	0.8960	0.8844	0.8752
RSA (2022)	0.6908	0.7806	0.8441	0.8850	0.9266	0.9409
SAO (2023)	0.6852	0.7806	0.8368	0.8802	0.9338	0.9459
Co-GoldSa	0.6943	0.7959	0.8468	0.8808	0.9297	0.9504
Test Image 5						
MVO (2015)	0.1879	0.1937	0.5791	0.4667	0.5818	0.6317
MFO (2015)	0.4680	0.3903	0.5195	0.5742	0.4749	0.5189
WOA (2016)	0.1879	0.1879	0.4493	0.5815	0.5463	0.5557
AOA (2021)	0.4012	0.4596	0.6847	0.7838	0.7943	0.8367
AO (2021)	0.4673	0.4673	0.7583	0.8420	0.8750	0.8664
CO (2022)	0.3390	0.6256	0.7205	0.7714	0.8247	0.8712
RSA (2022)	0.4673	0.6743	0.7492	0.823	0.8208	0.8445
SAO (2023)	0.4673	0.6732	0.757	0.8358	0.8708	0.8750
Co-GoldSa	0.4683	0.6752	0.7677	0.8429	0.8570	0.8688
Test Image 6						
MVO (2015)	0.0793	0.08	0.4621	0.3069	0.2773	0.5507
MFO (2015)	0.1378	0.5679	0.4286	0.7666	0.2267	0.2794
WOA (2016)	0.4188	0.1908	0.1253	0.4101	0.6686	0.4939
AOA (2021)	0.538	0.6819	0.8046	0.8742	0.8965	0.9113
AO (2021)	0.7112	0.7112	0.8197	0.8909	0.9003	0.9214
CO (2022)	0.5108	0.6984	0.7653	0.8916	0.9057	0.9257
RSA (2022)	0.7112	0.7264	0.8166	0.8739	0.9156	0.9169
SAO (2023)	0.7112	0.7041	0.8197	0.8647	0.9113	0.9305
Co-GoldSa	0.7115	0.7316	0.8197	0.8920	0.9209	0.9312

Ek- 11: Göğüs kanseri görüntülerinden elde edilen FSIM değerleri

Test Image 1						
	4	6	8	12	16	20
MVO (2015)	0.1972	0.1904	0.2457	0.2232	0.2128	0.1754
MFO (2015)	0.1365	0.1708	0.2759	0.4157	0.1670	0.2699
WOA (2016)	0.1365	0.1892	0.3064	0.2486	0.2194	0.2237
AOA (2021)	0.7283	0.7878	0.8687	0.8938	0.8556	0.9044
AO (2021)	0.7145	0.8159	0.8113	0.9083	0.9222	0.9352
CO (2022)	0.7018	0.8468	0.8615	0.9178	0.9288	0.918
RSA (2022)	0.7145	0.8476	0.7613	0.8893	0.9175	0.9315
SAO (2023)	0.7239	0.8159	0.8159	0.9102	0.9238	0.9245
Co-GoldSa	0.7889	0.8567	0.8886	0.9153	0.9298	0.9359
Test Image 2						
MVO (2015)	0.4283	0.4201	0.4878	0.6224	0.6891	0.6408
MFO (2015)	0.3814	0.4201	0.5502	0.5573	0.4402	0.6121
WOA (2016)	0.4283	0.4228	0.5513	0.5597	0.6119	0.6016
AOA (2021)	0.6429	0.7238	0.7871	0.896	0.926	0.9369
AO (2021)	0.6518	0.7928	0.8646	0.9032	0.9342	0.8839
CO (2022)	0.6365	0.7457	0.8323	0.8877	0.906	0.93
RSA (2022)	0.6518	0.8030	0.844	0.9018	0.8981	0.945
SAO (2023)	0.6518	0.7928	0.8646	0.9226	0.9377	0.9426
Co-GoldSa	0.6525	0.6829	0.8646	0.9319	0.9334	0.9486
Test Image 3						
MVO (2015)	0.3074	0.5805	0.5076	0.6206	0.6513	0.6887
MFO (2015)	0.1938	0.6781	0.4967	0.483	0.6602	0.6164
WOA (2016)	0.3074	0.4985	0.6033	0.5732	0.6338	0.6465
AOA (2021)	0.7387	0.8215	0.8299	0.8719	0.8876	0.9277
AO (2021)	0.7336	0.8151	0.8299	0.9018	0.9321	0.9402
CO (2022)	0.7245	0.8076	0.8048	0.8808	0.8622	0.906
RSA (2022)	0.7287	0.8129	0.8405	0.9016	0.9157	0.9341
SAO (2023)	0.7336	0.8151	0.8299	0.9025	0.9333	0.9446
Co-GoldSa	0.7436	0.8251	0.8515	0.9106	0.9344	0.9395
Test Image 4						
MVO (2015)	0.6744	0.179	0.7227	0.5578	0.6324	0.7553
MFO (2015)	0.6673	0.6094	0.7415	0.3413	0.6434	0.6746
WOA (2016)	0.6744	0.5355	0.6697	0.6223	0.6223	0.6018
AOA (2021)	0.7552	0.7945	0.807	0.876	0.9081	0.9256
AO (2021)	0.7521	0.7959	0.8422	0.9022	0.935	0.9587
CO (2022)	0.7917	0.7959	0.8726	0.8924	0.9363	0.9255
RSA (2022)	0.747	0.8097	0.8284	0.9077	0.935	0.9651
SAO (2023)	0.7521	0.7959	0.8284	0.8921	0.9431	0.9567
Co-GoldSa	0.7979	0.8504	0.8606	0.9232	0.9483	0.9651
Test Image 5						
MVO (2015)	0.3399	0.3528	0.7022	0.6359	0.7089	0.7355
MFO (2015)	0.5891	0.5646	0.6657	0.704	0.6400	0.6703
WOA (2016)	0.3399	0.3454	0.622	0.7086	0.6877	0.6926
AOA (2021)	0.5554	0.6261	0.7871	0.8644	0.8648	0.9071
AO (2021)	0.5891	0.7565	0.8347	0.8889	0.9210	0.9200
CO (2022)	0.5891	0.7565	0.8284	0.8931	0.9054	0.9213
RSA (2022)	0.5891	0.7551	0.8277	0.8861	0.8985	0.9091
SAO (2023)	0.5891	0.7565	0.831	0.8803	0.9054	0.9261
Co-GoldSa	0.6079	0.7565	0.8384	0.8931	0.9228	0.9213
Test Image 6						
MVO (2015)	0.2779	0.2766	0.5973	0.4761	0.4455	0.6503
MFO (2015)	0.3267	0.6311	0.577	0.7775	0.3914	0.4477
WOA (2016)	0.5441	0.3635	0.3101	0.5649	0.7099	0.6187
AOA (2021)	0.6177	0.7486	0.8597	0.9097	0.9323	0.9081
AO (2021)	0.7544	0.7715	0.8699	0.933	0.9381	0.9501
CO (2022)	0.6367	0.7709	0.8393	0.8955	0.9256	0.9521
RSA (2022)	0.7525	0.781	0.8585	0.9161	0.9361	0.9257
SAO (2023)	0.7544	0.7715	0.8699	0.9009	0.9439	0.9580
Co-GoldSa	0.7544	0.7921	0.8713	0.9335	0.9521	0.9566

Ek- 12: Göğüs kanseri görüntülerinden elde edilen PSNR değerleri

Test Image 1						
	4	6	8	12	16	20
MVO (2015)	7.9566	7.9585	9.1204	9.3028	9.3033	8.1994
MFO (2015)	4.9277	5.9014	9.7561	11.573	7.6499	10.3347
WOA (2016)	4.9277	7.9587	10.036	9.7595	9.4837	9.6673
AOA (2021)	12.613	13.685	17.315	18.370	19.7100	19.5492
AO (2021)	12.805	16.384	16.328	20.131	0.8393	22.2827
CO (2022)	11.123	16.647	16.098	19.825	21.5019	21.6683
RSA (2022)	12.805	16.549	15.547	20.078	20.6705	21.9407
SAO (2023)	12.782	16.384	16.384	20.115	21.1646	21.2828
Co-GoldSa	14.979	16.686	18.790	20.775	22.1571	22.4266
Test Image 2						
MVO (2015)	9.4652	9.5793	10.4334	12.7850	14.537	13.4545
MFO (2015)	9.0018	9.5793	11.2168	11.6299	10.188	12.8238
WOA (2016)	9.4652	9.5762	11.2039	11.6264	12.711	12.6239
AOA (2021)	11.3694	12.5289	15.9988	20.3807	22.169	24.6609
AO (2021)	11.6211	14.9498	17.6485	20.1908	0.9141	20.9246
CO (2022)	11.2478	13.1050	16.2265	19.1530	21.552	23.6293
RSA (2022)	11.6919	15.5464	16.8639	20.6499	21.351	24.8748
SAO (2023)	11.6211	14.9498	17.6485	20.8320	23.527	24.3354
Co-GoldSa	11.6211	15.7573	17.6485	20.9968	22.822	24.8903
Test Image 3						
MVO (2015)	7.5458	11.4418	10.1101	12.7731	13.8335	15.0533
MFO (2015)	6.7669	13.5714	9.9518	9.9829	13.8774	12.9268
WOA (2016)	7.5458	9.9172	12.1489	11.7636	13.3128	13.8603
AOA (2021)	12.9451	15.4819	16.7315	19.3055	19.4302	22.3015
AO (2021)	13.4957	15.9425	17.2283	20.4105	0.9250	22.9623
CO (2022)	13.0585	15.4936	16.2326	18.7489	19.8604	22.1526
RSA (2022)	13.4950	15.8714	17.1492	19.7213	21.5804	22.6375
SAO (2023)	13.4957	15.9425	17.2283	20.4296	22.2000	23.5850
Co-GoldSa	13.4957	15.9425	17.2283	20.1971	22.2504	22.8980
Test Image 4						
MVO (2015)	13.6924	7.2725	14.8307	12.1228	13.6849	17.3101
MFO (2015)	13.5401	11.6553	15.4293	9.7283	13.9173	14.7801
WOA (2016)	13.6924	11.4075	13.7226	13.2010	13.5775	13.3565
AOA (2021)	13.2983	13.8551	14.6243	18.6337	22.2984	19.9910
AO (2021)	13.0201	15.4692	17.3599	19.8802	0.9361	23.5690
CO (2022)	13.2388	15.5585	16.5892	20.3294	20.4670	20.1503
RSA (2022)	13.1368	16.0796	17.4820	19.3050	21.8337	23.6198
SAO (2023)	13.0201	15.4692	17.3139	19.3820	22.4482	23.5878
Co-GoldSa	13.7050	16.4692	17.5139	20.3855	22.0715	24.0936
Test Image 5						
MVO (2015)	9.9910	10.3963	16.0296	14.8352	16.8326	17.8833
MFO (2015)	13.4635	12.8827	15.0323	16.4609	15.2716	16.0856
WOA (2016)	9.9910	10.4014	14.1933	16.5980	16.3145	16.6264
AOA (2021)	10.8726	11.4887	15.9160	19.1085	20.4138	22.2462
AO (2021)	12.5975	16.2662	18.7401	21.7010	0.8750	23.2230
CO (2022)	9.8426	15.1983	17.8366	19.2237	21.5538	23.2303
RSA (2022)	12.5975	16.3015	18.5024	21.0675	21.3587	22.7062
SAO (2023)	12.5975	16.2662	18.7500	21.5490	23.3606	23.7453
Co-GoldSa	14.5975	16.3662	18.7963	21.7187	23.5253	23.2661
Test Image 6						
MVO (2015)	5.8980	5.9607	12.2486	10.9368	10.6582	14.0296
MFO (2015)	7.3626	12.2915	11.9680	16.4723	9.9288	10.8517
WOA (2016)	10.9382	8.4003	7.3679	11.8857	15.1396	13.3350
AOA (2021)	10.9841	13.7829	17.6782	21.1934	22.7330	22.1751
AO (2021)	14.5638	15.2010	17.8931	21.3916	0.9003	23.4807
CO (2022)	9.7406	14.4238	17.0077	20.6005	23.2505	24.2569
RSA (2022)	14.5380	15.2408	17.8329	20.6268	22.7546	22.5708
SAO (2023)	14.5638	15.2010	17.8931	21.5584	22.5587	24.3790
Co-GoldSa	14.5638	15.5197	18.7278	21.7067	23.6566	24.2545