



T.C.

BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**TIBBİ GÖRÜNTÜLERDE ÇOKLU EŞİKLEME: OTSU, KAPUR VE HİBRİT
ENTROPY FONKSİYONLARI TEMELLİ OPTİMİZASYON ALGORİTMALARININ
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

NECDET BURAK KARVAN

TEZ DANIŞMANI
Dr. Öğr. Üyesi SALİM CEYHAN

BİLECİK, 2026
10775502

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

**TIBBİ GÖRÜNTÜLERDE ÇOKLU EŞİKLEME: OTSU, KAPUR VE HİBRİT
ENTROPY FONKSİYONLARI TEMELLİ OPTİMİZASYON ALGORİTMALARININ
KARŞILAŞTIRMALI ANALİZİ**

YÜKSEK LİSANS TEZİ

NECDET BURAK KARVAN

TEZ DANIŞMANI
Dr. Öğr. Üyesi SALİM CEYHAN

BİLECİK, 2026
10775502

BEYAN

"Tıbbi Görüntülerde Çoklu Eşikleme: Otsu, Kapur ve Hibrit Entropy Fonksiyonları Temelli Optimizasyon Algoritmalarının Karşılaştırmalı Analizi" başlıklı yüksek lisans tezimin hazırlık ve yazım aşamasında bilimsel araştırma ve etik kurallarına uyduğumu, Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Faaliyetlerinde Üretken Yapay Zekâ Kullanımına Dair Etik Rehberine uygun olarak tez/dönem projemi hazırladığımı, başkalarının eserlerinden yararlandığım bölümlerde bilimsel etik kurallarına uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, çalışmamın herhangi bir kısmının başka bir tez/dönem projesi olarak sunulmadığını, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

NECDET BURAK KARVAN

.././20..

İmza:

ÖN SÖZ

Tez çalışmamın her aşamasında yardımlarını ve desteklerini hiçbir zaman esirgemeyen danışmanım çok değerli hocam sayın Dr. Öğr. Üyesi Salim CEYHAN 'a teşekkürlerimi ve saygılarımı sunarım.

NECDET BURAK KARVAN

2026

ÖZET

Çalışma, gri tonlamalı beyin MR görüntülerinde çok seviyeli eşikleme sorununa yönelik üç amaç fonksiyonunu karşılaştırır: Otsu, Kapur ve bunların entropi-varyans tabanlı hibriti. Çalışma kapsamında; Guguk Kuşu Araması (CS), Diferansiyel Evrim (DE), Ateş Böceği (FFA), Parçacık Sürüsü (PSO), Balina (WOA) ve Savaş Stratejisi (WSOA) algoritmaları, Lower-Grade Glioma veri tabanındaki 110 hastaya ait dilimlerde kapsamlı bir performans ön değerlendirmesine tabi tutulmuştur. Bu ön analizler sonucunda yakınsama kararlılığı ve segmentasyon başarısı düşük kalan algoritmalar elenmiş; detaylı optimizasyon süreçleri Parçacık Sürüsü (PSO) ve Guguk Kuşu (CS) algoritmaları üzerine yoğunlaştırılmıştır. Segmentasyon kalitesi Dice Benzerlik Katsayısı (DSC), Jaccard İndeksi (IoU), Hausdorff Mesafesi (HD95) ve Boundary-F1 skorları ile ölçülmüştür. Deneyler, önerilen hibrit entropi-varyans fonksiyonunun özellikle PSO algoritması (PSO-Hybrid) ile birlikte kullanıldığında, tekil yöntemlere (Otsu ve Kapur) ve standart CS tabanlı yaklaşımlara kıyasla hem sayısal hem de algısal ölçütlerde en yüksek doğruluğu sağladığını göstermektedir. Bulgular, meta-sezgisel optimizasyonun hibrit amaç fonksiyonlarıyla entegrasyonunun, beyin tümörü segmentasyonunda sınır hatalarını anlamlı biçimde azalttığını doğrular.

Anahtar Kelimeler: Çok seviyeli eşikleme, görüntü kalitesi değerlendirmesi, hibrit entropi-varyans, meta-sezgisel Optimizasyon, MRG beyin bölütlemesi.

ABSTRACT

The study compares three objective functions for the multi-level thresholding problem in grayscale brain MR images: Otsu's method, Kapur's entropy, and their entropy-variance-based hybrid. Within the scope of the study, Cuckoo Search (CS), Differential Evolution (DE), Firefly (FFA), Particle Swarm Optimization (PSO), Whale Optimization Algorithm (WOA), and War Strategy Optimization (WSOA) algorithms were subjected to a comprehensive preliminary performance evaluation on slices from 110 patients in the Lower-Grade Glioma database. As a result of these preliminary analyses, algorithms demonstrating low convergence stability and segmentation success were eliminated, and detailed optimization processes were focused on Particle Swarm Optimization (PSO) and Cuckoo Search (CS) algorithms. Segmentation quality was measured using the Dice Similarity Coefficient (DSC), Jaccard Index (IoU), Hausdorff Distance (HD95), and Boundary-F1 scores. Experiments demonstrate that the proposed hybrid entropy-variance function, especially when combined with the PSO algorithm (PSO-Hybrid), achieves the highest accuracy in both numerical and perceptual metrics compared to singular methods (Otsu and Kapur) and standard CS-based approaches. The findings confirm that the integration of meta-heuristic optimization with hybrid objective functions significantly reduces boundary errors in brain tumor segmentation.

Keywords: Hybrid entropy–variance, image quality assessment, meta-heuristic optimization, MRI brain segmentation, multilevel thresholding.

İÇİNDEKİLER

	Sayfa
ÖN SÖZ	i
ÖZET	ii
ABSTRACT	iii
TABLolar LİSTESİ	vi
ŞEKİLLER LİSTESİ	viii
KISALTMALAR VE SİMGELER LİSTESİ	ix
1. GİRİŞ	1
1.1. Tezin Amacı	1
1.2. Araştırma Kapsamı	2
1.3. Genel Bilgiler	2
2. LİTERATÜR ARAŞTIRMASI	4
3. MATERYAL VE YÖNTEM	7
3.1. Önerilen Sistemin Mimarisi	7
3.2. Veri Seti	8
3.3. Meta-Sezgisel Algoritmalar	11
3.3.1. Guguk kuşu arama optimizasyon algoritması	11
3.3.2. Parçacık sürüsü optimizasyon algoritması	12
3.4. Görüntü Eşikleme Algoritmaları	13
3.4.1. Otsu yöntemi	13
3.4.2. Kapur yöntemi	13
3.4.3. Rényi yöntemi	14
3.5. Ön İşleme	14
3.6. Çoklu Eşik Optimizasyonu	15
3.7. Sınıf Haritalama ve Bölütleme	17
3.8. Başarım Ölçütleri ve Değerlendirme	19
3.8.1. Performans ölçütleri	19
3.8.1.1Grafiksel değerlendirme yöntemleri	21
4. DENEYSEL ÇALIŞMALAR	25
4.1. Algoritma ve Sistem Parametreleri	25
4.1.1. Meta sezgisel algoritma işlem süreleri	27
4.2. Tümör Hacmine Göre Alt Grup Analizleri	28

4.3. Optimizasyon Profillerinin Karşılaştırmalı Analizi	31
4.3.1. Dengeli-Tam profili analizi	32
4.3.2. Hızlı-Tam profili analizi	35
4.3.3. Ön işleme adımının etkisi	39
4.3.4. Son işleme adımlarının etkisi	43
4.3.5. Hibrit amaç fonksiyonunda parametrik duyarlılık rényi ağırlıklı .	47
5. SONUÇLAR VE TARTIŞMA	52
KAYNAKÇA	54
EKLER	57

TABLO LİSTESİ

	Sayfa
Tablo 4.1. Meta-Sezgisel algoritma parametreleri	26
Tablo 4.2. Eşik seviyelerine göre algoritma popülasyon büyüklükleri	26
Tablo 4.3. Hibrit amaç fonksiyonu ve genel sistem parametreleri	27
Tablo 4.4. Q1-Küçük hacimli tümörlere ait Dice ve ASSD sonuçları	29
Tablo 4.5. Q1-Küçük hacimli tümörlere ait HD95 ve Boundary F1 sonuçları	29
Tablo 4.6. Q2-Orta hacimli tümörlere ait Dice ve ASSD sonuçları	29
Tablo 4.7. Q2-Orta hacimli tümörlere ait HD95 ve Boundary F1 sonuçları	30
Tablo 4.8. Q3-Orta hacimli tümörlere ait Dice ve ASSD sonuçları	30
Tablo 4.9. Q3-Orta hacimli tümörlere ait HD95 ve Boundary F1 sonuçları	30
Tablo 4.10. Q4-Büyük hacimli tümörlere ait Dice ve ASSD sonuçları	31
Tablo 4.11. Q4-Büyük hacimli tümörlere ait HD95 ve Boundary F1 sonuçları	31
Tablo 4.12. Genel Dice katsayısı	31

ŞEKİL LİSTESİ

	Sayfa
Şekil 3.1. Akış diyagramı	8
Şekil 3.2. TCIA-LGG veri setinden seçilen farklı hastalara ait kesit örnekleri.	10
Şekil 4.1. Algoritmaların işlem süreleri karşılaştırması	28
Şekil 4.2. Dengeli-Tam profilinde Dice katsayısı dağılımı	33
Şekil 4.3. Dengeli-Tam profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği	33
Şekil 4.4. Dengeli-Tam profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı	34
Şekil 4.5. Dengeli-Tam profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi	34
Şekil 4.6. Dengeli-Tam profilinde yüksek başarımlı sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları	35
Şekil 4.7. Hızlı-Tam profilinde Dice katsayısı frekans dağılımı	36
Şekil 4.8. Hızlı-Tam profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği	36
Şekil 4.9. Hızlı-Tam profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı	37
Şekil 4.10. Hızlı-Tam profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi	38
Şekil 4.11. Hızlı-Tam profilinde yüksek başarımlı sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları	39
Şekil 4.12. Kontrast iyileştirme uygulanmayan profilinde Dice katsayısı dağılımı	40
Şekil 4.13. Kontrast iyileştirme uygulanmayan profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği	41
Şekil 4.14. Kontrast iyileştirme uygulanmayan profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı	41
Şekil 4.15. Kontrast iyileştirme uygulanmayan profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi	42
Şekil 4.16. Kontrast iyileştirme uygulanmayan profilinde yüksek başarımlı sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları	43
Şekil 4.17. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde Dice katsayısı dağılımı	44
Şekil 4.18. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği	45

Şekil 4.19. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı	45
Şekil 4.20. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi .	46
Şekil 4.21. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde yüksek başarımla sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları	47
Şekil 4.22. Rényi Entropi ağırlıklı hibrit fonksiyon kullanlan profilinde Dice katsayısı dağılımı	48
Şekil 4.23. Rényi Entropi ağırlıklı hibrit fonksiyon kullanlan profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği	48
Şekil 4.24. Rényi Entropi ağırlıklı hibrit fonksiyon kullanlan profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı	49
Şekil 4.25. Rényi Entropi ağırlıklı hibrit fonksiyon kullanlan profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi	50
Şekil 4.26. Rényi Entropi ağırlıklı hibrit fonksiyon kullanlan profilinde yüksek başarımla sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları	51

KISALTMALAR VE SİMGELER LİSTESİ

- ASSD:** Ortalama Simetrik Yüzey Mesafesi (Average Symmetric Surface Distance)
- AVD:** Mutlak Hacim Farkı (Absolute Volume Difference)
- BAP:** Bilimsel Araştırma Projeleri
- CDF:** Kümülatif Dağılım Fonksiyonu (Cumulative Distribution Function)
- CLAHE:** Kontrast Sınırlı Adaptif Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization)
- CS:** Guguk Kuşu Arama (Cuckoo Search)
- DE:** Diferansiyel Evrim (Differential Evolution)
- DICOM:** Tıpta Dijital Görüntüleme ve İletişim (Digital Imaging and Communications in Medicine)
- DSC:** Dice Benzerlik Katsayısı (Dice Similarity Coefficient)
- FFA:** Ateş Böceği Algoritması (Firefly Algorithm)
- FLAIR:** Sıvı Bastırılmış Ters Çevirim İyileşme (Fluid Attenuated Inversion Recovery)
- FSIM:** Özellik Benzerlik İndeksi (Feature Similarity Index)
- GT:** Yer-Gerçek (Ground Truth)
- HD95:** Hausdorff Mesafesi 95. Yüzdeleri (Hausdorff Distance 95th Percentile)
- IoU:** Kesişim ve Birleşim Oranı (Intersection over Union)
- LGG:** Düşük Dereceli Glioma (Lower-Grade Glioma)
- MGCE:** Minimum Genelleştirilmiş Çapraz Entropi (Minimum Generalized Cross-Entropy)
- MRG:** Manyetik Rezonans Görüntüleme (Magnetic Resonance Imaging - MRI)
- MSE:** Ortalama Kare Hata (Mean Squared Error)
- PSO:** Parçacık Sürüsü Optimizasyonu (Particle Swarm Optimization)
- PSNR:** Tepe Sinyal-Gürültü Oranı (Peak Signal-to-Noise Ratio)
- ROI:** İlgi Alanı (Region of Interest)
- RVD:** Bağlı Hacim Farkı (Relative Volume Difference)
- SSIM:** Yapısal Benzerlik İndeksi (Structural Similarity Index)
- TCIA:** Kanser Görüntüleme Arşivi (The Cancer Imaging Archive)
- WOA:** Balina Optimizasyon Algoritması (Whale Optimization Algorithm)
- WSOA:** Savaş Stratejisi Optimizasyon Algoritması (War Strategy Optimization Algorithm)

1. GİRİŞ

Görüntü segmentasyonu, tıbbi tanıdan uzaktan algılamaya kadar çok sayıda uygulamada, ham pikselleri semantik olarak anlamlı alt bölgelere ayırarak üst-düzey analizlerin yapılmasına olanak tanıyan temel bir adımdır. (Khan, 2013; Sharma vd., 2023; X. Zhang vd., 2025) Literatürde bölge tabanlı, kümeleme tabanlı, kenar tabanlı, watershed, yapay sinir ağı tabanlı ve eşikleme tabanlı yöntemler gibi çeşitli segmentasyon stratejileri mevcuttur. Bu stratejiler içinde eşikleme (Tao vd., 2007) , histogram istatistiklerine dayalı basit mimarisi (Gonzalez ve Woods, 2008) ve düşük hesaplama maliyeti sayesinde yaygın olarak tercih edilmektedir (Bovik, 2009). Otsu ve Kapur yöntemleri eşiklemeye yönelik iki klasik yaklaşımı temsil eder. Otsu yöntemi sınıflar arası varyansı maksimize ederek parametrik olmayan bir optimum eşik değeri üretirken (Otsu, 1979); Kapur yöntemi, toplam bilgi entropisini maksimize eden eşikler seçerek karmaşık dağılımlı görüntülerde daha dengeli sınırlar elde etmeyi amaçlar (Kapur vd., 1985). Ancak çok seviyeli eşikleme, arama uzayının üstel biçimde büyümesi nedeniyle NP-zor bir optimizasyon problemine dönüşür (Bhandari vd., 2015; Hussein vd., 2016). Son dönemde bu zorluk, meta-sezgisel algoritmaların keşif-sömürü dengesi sağlayan nümerik yetenekleriyle aşılmaktadır. Bu makalenin katkıları üç başlıkta özetlenebilir:

1. Otsu ve Kapur ölçütlerini normalize ederek birleştiren yeni bir hibrit fitness fonksiyonu önerme,
2. Farklı meta-sezgisel algoritmaları (CSO, DE, FFA, PSO, WOA, WSOA) kullanarak çok seviyeli eşikleme için optimum eşik vektörlerini arama,
3. Segmentasyon doğruluğunu Dice ve Jaccard (IoU) örtüşme oranları, Precision/Recall-F1 sınıf-dengesi ölçütleri ile sınır duyarlı Hausdorff Distance (HD95) üzerinden değerlendirerek yöntemler arası klinik açıdan anlamlı bir karşılaştırma sunma.

Çalışma devamı şu şekilde organize edilmiştir: Bölüm II, çok seviyeli eşikleme ve meta-sezgisel optimizasyon alanındaki ilgili çalışmaları incelemektedir. Bölüm III, çalışmanın metodolojik çerçevesini sunmakta; bu kapsamda kullanılan LGG veri kümesini, uygulanan ön işleme adımlarını, optimize edilen hibrit amaç fonksiyonlarını ve kullanılan segmentasyon performans ölçütlerini detaylandırmaktadır. Bölüm IV, yürütülen deneysel çalışmaların nicel sonuçlarını sunmakta ve elde edilen bulguları literatür bağlamında tartışmaktadır. Son olarak, Bölüm V, çalışmanın genel bir değerlendirmesini yaparak ana katkıları özetlemekte ve gelecekteki araştırma yönlerini sunmaktadır.

1.1. Tezin Amacı

Tıbbi görüntüleme tekniklerinden biri olan Manyetik Rezonans Görüntüleme (MRG), beyin tümörlerinin teşhisi, tedavi planlaması ve takibinde hayati bir rol oynamaktadır (Nyúl ve Udupa, 1999). Ancak, MR görüntülerinden tümörlü dokunun sağlıklı dokudan beyaz cevher, gri

cevher, beyin omurilik sıvısı gibi olan ayrıştırılması işlemi, dokular arasındaki düşük kontrast farkları, düzensiz sınırlar ve görüntü gürültüleri nedeniyle oldukça zorlu bir problemdir. Manuel segmentasyon işleminin zaman alıcı olması ve uzmanlar arasında öznel farklılıklar göstermesi, tam otomatik ve yüksek doğruluklu bilgisayar destekli sistemlere olan ihtiyacı artırmaktadır.

Bu tezin temel amacı gri tonlamalı beyin MR görüntülerinde tümör segmentasyonu başarımını artırmak için hibrit bir amaç fonksiyonu ve meta-sezgisel optimizasyon algoritmalarına dayalı, yüksek performanslı bir çok seviyeli eşikleme yöntemi geliştirmektir. Bu kapsamda hedeflenen alt amaçlar; öncelikle Otsu eşikleme (Tao vd., 2007), Kapur ve Rényi entropisi (Rényi, 1961; Sahoo vd., 1997) yöntemlerinin güçlü yönlerini birleştiren ve histogramdaki belirsizlikleri minimize eden yeni bir hibrit uygunluk fonksiyonunun önerilmesidir. Buna paralel olarak, çok seviyeli eşiklemede seviye sayısı arttıkça üstel olarak büyüyen arama uzayı probleminin çözümünde, optimum eşik değerlerini makul sürelerde tespit edebilmek adına Parçacık Sürüsü Optimizasyonu (Kennedy ve Eberhart, 1995) ve Guguk Kuşu (Yang ve Deb, 2009) Arama gibi meta-sezgisel algoritmaların etkinliğinin analiz edilmesi hedeflenmiştir. Çalışmanın nihai aşamasında ise, önerilen sistemin segmentasyon doğruluğunun Dice Benzerlik Katsayısı (Taha ve Hanbury, 2015), Hausdorff Mesafesi (Mehta vd., 2022) ve Boundary-F1 (Yeghiazaryan ve Voiculescu, 2018) gibi klinik açıdan geçerli metrikler üzerinden ölçülmesi ve elde edilen bulguların literatürdeki standart yöntemlerle karşılaştırmalı olarak değerlendirilmesi amaçlanmaktadır.

1.2. Araştırma Kapsamı

Bu tez çalışması, The Cancer Imaging Archive (TCIA) (Clark vd., 2013) veri tabanında yer alan ve tümör varlığı uzmanlarca doğrulanmış 110 farklı hastaya ait ameliyat öncesi FLAIR sekanslı Lower-Grade Glioma (LGG) (Pedano vd., 2016) görüntüleri üzerinde yürütülmüştür. Çalışmada kullanılan görüntü işleme hattı; kafatası sıyırma, histogram eşitleme ve medyan filtreleme gibi ön işlemlerden (Soille, 2004) başlayarak çok seviyeli eşikleme optimizasyonu ve morfolojik sonlandırma adımlarını kapsamaktadır. Eşik değerlerinin optimizasyonu sürecinde literatürdeki yaygın meta-sezgisel algoritmalar (DE (Storn ve Price, 1997), FFA (Yang, 2009), WOA (Mirjalili ve Lewis, 2016), WSOA (Ayyarao vd., 2022)) ön değerlendirmeye tabi tutulmuş; nihai analizler ve hibrit modelleme, en yüksek kararlılığı sergileyen Parçacık Sürüsü Optimizasyonu ve Guguk Kuşu Arama algoritmaları ile sınırlandırılmıştır. Algoritmaların performansı, düşük ve yüksek karmaşıklık düzeylerini temsil eden farklı eşik sayıları üzerinde test edilirken, başarımların ölçümü piksel tabanlı örtüşme metriklerinin (Csurka vd., 2013; Nai vd., 2021) yanı sıra mesafe tabanlı ölçütler ve istatistiksel analizlerle desteklenmiştir (Arbeláez vd., 2011). Çalışma, 2 boyutlu kesitler üzerindeki gri seviye eşikleme tekniklerine odaklanmış olup, 3 boyutlu hacimsel analizler ve derin öğrenme tabanlı modellerin eğitimi kapsam dışı bırakılmıştır.

1.3. Genel Bilgiler

Görüntü segmentasyonu, dijital bir görüntüyü analiz edilebilir anlamlı bölgelere ayırma işlemi olup, tıbbi görüntüleme patolojik alanların tespiti için kritik öneme sahiptir. Bu yöntemler arasında yer alan eşikleme, basitliği ve hesaplama hızı sayesinde yaygın olarak tercih

edilmekte; tek bir sınır deęeri kullanıldığında ikili, birden fazla deęer kullanıldığında ise çok seviyeli eşikleme olarak adlandırılmaktadır. Ancak eşik sayısının artmasıyla birlikte olası kombinasyonların üstel olarak büyümesi, problemi NP-zor sınıfına sokarak optimum deęerlerin geleneksel yöntemlerle bulunmasını imkansız hale getirmektedir. Bu hesaplama zorluęunu aşmak amacıyla, arama uzayını rastgelelik ve belirli kurallar çerçevesinde tarayan doğa esinli meta-sezgisel optimizasyon algoritmaları kullanılmaktadır (Guo vd., 2024; Ma ve Hu, 2024).

Çalışmada, eşikleme kalitesini belirlemek için üç temel yaklaşım esas alınmıştır. Sınıflar arası varyansı maksimize ederek nesne ve arka planı ayıran Otsu yöntemi, histogramın entropisini maksimize ederek bilgi kaybını azaltan Kapur yöntemi ve parametrik yapısı sayesinde histogram özelliklerine duyarlı olan Rényi entropisi bu yaklaşımların temelini oluşturur. Tezde önerilen yöntem ise, bu tekniklerin tekil zayıflıklarını gidermek amacıyla varyans ve entropi tabanlı kriterleri birleştiren hibrit bir yapı üzerine kurgulanmıştır.

2. LİTERATÜR ARAŞTIRMASI

Son yıllarda çok seviyeli eşikleme ve tıbbi görüntü segmentasyonu alanında yapılan çalışmalar, özellikle meta-sezgisel algoritmaların bu sürece entegre edilmesiyle önemli ilerlemeler kaydetmiştir. Bu bölümde, literatürde ilgili yöntemler özetlenmektedir.

S.R. Sharma ve ark. çalışmasında (Sharma vd., 2023), iki aşamalı hibrit bir yöntem önerilmiştir. İlk aşamada, MRI görüntülerinde optimal çok seviyeli eşik değerlerinin belirlenmesi amacıyla Dynamic Opposite Bald Eagle Search (DOBES) algoritması kullanılmıştır (Sharma vd., 2023). İkinci aşamada ise, morfolojik işlemler uygulanarak istenmeyen bölgeler görüntüden temizlenmiş ve tümör bölgesi daha net bir şekilde ayrıştırılmıştır. DOBES algoritması, Bald Eagle Search (BES) algoritmasında karşılaşılan yavaş yakınsama hızı ve yerel optima takılma problemlerini aşmak üzere Dinamik Muhalefet Öğrenme (Dynamic Opposition Learning) stratejisiyle geliştirilmiştir. Bu algoritmada Kapur'un entropisi (Kapur vd., 1985), maliyet fonksiyonu olarak tercih edilmiştir. Morfolojik işlemler kapsamında kenar algılama, görüntü genişletme, sınır belirleme, istenmeyen alanların kaldırılması ve alan doldurma gibi adımlar uygulanmıştır. Bu yaklaşım, elde edilen segmentasyon sonuçlarının daha yüksek doğruluk ve yapısal benzerlik (SSIM) (Wang vd., 2004) değerlerine sahip olduğunu, aynı zamanda düşük ortalama kare hata (MSE) ile segmentasyonun gerçek tümör alanlarıyla daha uyumlu olduğunu ortaya koymaktadır.

B.Jena ve ark. incelemesinde (Jena vd., 2022), eşikleme sürecinde maliyet fonksiyonu olarak Minimum Generalized Cross-Entropy (MGCE) tabanlı bir yöntem kullanılmıştır. MGCE, tahmini sınıf dağılımı ile gözlemlenen histogram dağılımı ve varsa ön bilgi (prior distribution) arasındaki bilgi kuramsal uzaklığı en aza indirmeyi amaçlayan bir yaklaşımdır. Bu çalışmada geliştirilen Opposition African Vulture Optimization Algorithm (OAVOA), geleneksel African Vulture Optimization Algorithm (AVOA)'dan farklı olarak Opposition-Based Learning yöntemiyle zenginleştirilmiştir. Ayrıca, Gaussian mutasyon işlemi ile çözümler üzerinde lokal alandaki sıkışmaları azaltmak amacıyla rastgele küçük değişiklikler yapılmıştır. Harvard Medical School'a ait T2-ağırlıklı beyin MR görüntüleri veri seti üzerinde gerçekleştirilen çok aşamalı segmentasyon işlemi, görüntülerdeki farklı nesnelere ve arka plana tekdüze yoğunluklar atamak amacıyla uygulanmıştır. Eşikleme seviyeleri artırdıkça, PSNR, SSIM ve FSIM (L. Zhang vd., 2011) gibi metriklerde artış gözlemlenmiştir. Bu durum, daha fazla eşik seviyesiyle segmentasyonun daha ayrıntılı sonuçlar üretebildiğini göstermektedir. İlgili metriklerin ortalama değerleri incelendiğinde, en yüksek sonuçların genellikle OAVOA-MGCE yöntemiyle elde edildiği rapor edilmiştir.

U.K. Acharya ve S.Kumar çalışmasında (Acharya ve Kumar, 2021), görüntünün histogramı çıkarıldıktan sonra kırpma eşiği, yoğunluk değerinin ortalaması ve medyanı alınarak hesaplanmakta ve buna göre ilgili histogram yeniden oluşturulmaktadır. Görüntü, ışıktandırma eşiği (Et) kullanılarak düşük pozlama ve yüksek pozlama olmak üzere iki bölgeye ayrılmıştır. Daha sonra, bu bölgeler optimal eşik değerleri olan Etl ve Etu ile tekrar ikiye bölünerek

yeni alt-histogramlar elde edilmiştir. Her bir alt-histogram için mevcut olasılık yoğunluk tabanlı maliyet fonksiyonu güncellenmekte ve bu fonksiyonlar kullanılarak kümülatif dağılım fonksiyonları hesaplanmaktadır. Bu kümülatif dağılımlara dayanarak, her alt-histogram için bir eşitleme fonksiyonu oluşturulmuştur. Görüntülerin yapısal karmaşıklığı nedeniyle, *Et*, *Etl* ve *Et_u* gibi eşik değerlerinin en uygun şekilde belirlenmesi için genetik algoritma kullanılmıştır. Genetik algoritma, her iterasyonda maliyet fonksiyonunu maksimize etmeye çalışarak en iyi parametre kombinasyonunu bulmayı amaçlamaktadır. Elde edilen dört eşitlenmiş alt-görüntü birleştirilerek geliştirilmiş yeni bir görüntü oluşturulmuştur. Çalışmada önerilen Genetik Algoritma Tabanlı Uyarlanabilir Histogram Eşitleme (GAAHE) yönteminin, kullanılan metriklerde anlamlı iyileştirmeler sağladığı gösterilmiştir. Parlaklık korunmuş, gürültüye karşı dayanıklılık artırılmıştır. GAAHE'nin mevcut bilgiyi koruyarak optimum sonuçlar üretmesi, genetik algoritma ile gerçekleştirilen etkili parametre seçimine dayanmaktadır.

Huang ve ark. çalışmasında (Huang vd., 2020), görüntü segmentasyonunda kullanılan çok seviyeli eşikleme tekniği, algılama ve tespit işlemleri için uygulanmıştır. Son yıllarda bu işlemler, meta-sezgisel algoritmalarla birlikte optimize edilerek daha etkili hâle getirilmiştir. Çok seviyeli eşikleme problemleri için komşular arası bilgi paylaşımını artıran bir varyant olan Fully Informed Cuckoo Search (FICS) algoritması önerilmiştir. FICS'in, orijinal Cuckoo Search (CS) (Yang ve Deb, 2009) algoritması ve diğer iki CS modifikasyonuna kıyasla daha yüksek performans ve görüntü kalitesi sağladığı ortaya konmuştur. Çalışma, FICS algoritmasının çok seviyeli eşikleme problemlerinde istatistiksel olarak anlamlı sonuçlar verdiğini göstermektedir. Özellikle standart sapma değerlerinin çoğunlukla sifıra çok yakın olması, algoritmanın kararlı ve tutarlı sonuçlar ürettiğini kanıtlamaktadır. Ayrıca, PSNR ve SSIM (Wang vd., 2004) gibi görüntü kalitesi metriklerinde elde edilen yüksek değerler, FICS'in daha başarılı segmentasyon sonuçları sunduğunu desteklemektedir.

Y. Uzun ve M. Bilgin araştırmasında (Uzun ve Bilgin, 2025), görüntü iyileştirme sürecinde bilgi kaybını en aza indirmek amacıyla Adaptive Histogram Equalization (AHE), War Strategy Optimization (WSO) (Ayyarao vd., 2022) ve Real Coded Genetic Algorithm (RCGA) yöntemleri birlikte kullanılmıştır. AHE, görüntü kontrastını artırmak için histogramdaki yoğunluk değerlerinin aralığını temel alarak pikselleri yeniden dağıtan bir tekniktir. Bu yöntemde, görüntü alt bölgelerine ayrılarak yerel histogram eşitlemesi gerçekleştirilmekte ve bu sayede daha ayrıntılı bir iyileştirme sağlanmaktadır. Öte yandan, WSO ve RCGA algoritmalarında elitizm stratejisi uygulanmıştır. Elitizm, evrimsel algoritmaların rastlantısal doğası gereği iyi çözümlerin sonraki nesillerde kaybolmasını engelleyen bir yaklaşımdır. Bu strateji, çözüm sürecinin istikrarlı ve güvenilir bir şekilde ilerlemesine katkı sağlar. Ancak, elitizmin aşırı kullanımı popülasyon çeşitliliğini azaltarak algoritmanın yerel minimumlara takılma riskini artırabilir. Bu nedenle çalışmada, elitizmin dengeleyici bir biçimde uygulanmasına özen gösterilmiştir. elitizmsiz WSO algoritmasının, görüntü iyileştirme yöntemlerinden biri olan histogram eşitlemede, GA yöntemine kıyasla bazı durumlarda benzer veya daha iyi sonuçlar verdiği gözlemlenmiştir. Yapılan testlerde, elitizmsiz WSO algoritmasının hem daha hızlı çalıştığı hem de zamansal ve kavramsal

karmaşıklık açısından üstünlük sağladığı belirlenmiştir. Elitizmsiz WSO algoritması genellikle daha yüksek ortalama uygunluk değeri ve daha iyi en iyi sonuçlar üretmiş, aynı zamanda düşük standart sapma değerleriyle daha istikrarlı performans göstermiştir.

Çok seviyeli eşikleme, gri-seviye histogramında m adet eşik değerinin aranması problemi- dir; birleşimsel uzayın $O(256^m)$ ölçeğinde büyümesi nedeniyle amaç fonksiyonları çoğunlukla popülasyon temelli meta-sezgisel yöntemlerle en iyilenir. Son dönemde literatür, özellikle entropi-tabanlı (Kapur vd., 1985; Rényi, 1961) ve histogram eşitleme temelli formülasyonlara yoğunlaşmış; amaç yüzeyinin çok kipli doğası, keşif-sömürü dengesi ve popülasyon/durdurma kurallarının standardizasyonu öne çıkmıştır. Sharma vd. (Sharma vd., 2023), Kapur entropi- sini Dynamic Opposite Bald Eagle Search (DOBES) ile optimize etmiş, dinamik muhalefet öğrenmesi ile yerel eniyilere sıkışmayı azaltmıştır. Morfolojik sonrası işlem dizisi eşliğinde MSE düşüşü ve SSIM artışı rapor edilmiştir; ancak eşikleme katkısının morfolojik adımlardan istatistiksel olarak ayrıştırılmaması metodik bir sınırlılık olarak kalmıştır. Jena vd. (Jena vd., 2022), sınıf histogramı ve olası önbilgilerle uyumu ölçen Minimum Generalized Cross-Entropy (MGCE) fonksiyonunu Opposition-AVOA ile eniyileyerek Harvard T2-ağırlıklı MR dilimlerinde eşik sayısı arttıkça PSNR/SSIM/FSIM metriklerinin düzenli yükseldiğini göstermiş; buna karşın zaman/karmaşıklık profili ve anlamlılık analizleri sınırlı kalmıştır. Acharya ve Kumar (Acharya ve Kumar, 2021) ise histogram kırpma eşiklerini (Et, Etl, Etu) Genetik Algoritma ile ortak en iyileyen GAAHE yaklaşımıyla parlaklık korunumu ve görsel kalite metriklerinde kazanım sağlamış, fakat doğrudan sınıf ayırımından ziyade kontrast yeniden-dağıtımına dayanması nedeniyle parametre duyarlılığı yüksek bir çerçeve sunmuştur. Bu hat üzerinde mevcut literatür üç bakımdan sınırlıdır:

1. Tekil bilgi ölçütlerine (Kapur (Kapur vd., 1985), MGCE) bağımlılık; entropi ile sınıf- içi varyans bilgisini ölçek-uyumlu biçimde birleştiren amaç fonksiyonlarının sistematik incelenmemesi,
2. Değerlendirmenin çoğunlukla MSE/PSNR ile sınırlı kalıp algısal (SSIM (Wang vd., 2004), FSIM (L. Zhang vd., 2011)) ve sınır-duyarlı ölçütlerin ikincil bırakılması,
3. Popülasyon büyüklüğü, iterasyon/durdurma kuralları ve rastgelelik kontrolü açısından algoritmalar arası adil karşılaştırma protokollerinin yeterince standardize edilmemesi.

Bu çalışma, söz konusu boşluğu hibrit entropi-varyans amaç fonksiyonunu altı popü- lasyon temelli meta-sezgisel (CS (Yang ve Deb, 2009), DE (Storn ve Price, 1997), FFA (Yang, 2009), PSO (Kennedy ve Eberhart, 1995), WOA (Mirjalili ve Lewis, 2016), WSOA (Ayyarao vd., 2022)) altında ortak ve denetlenmiş bir protokolle sınavarak ve MSE, PSNR, SSIM, FSIM üzerinden bütüncül bir değerlendirme sunarak ele almaktadır.

3. MATERYAL VE YÖNTEM

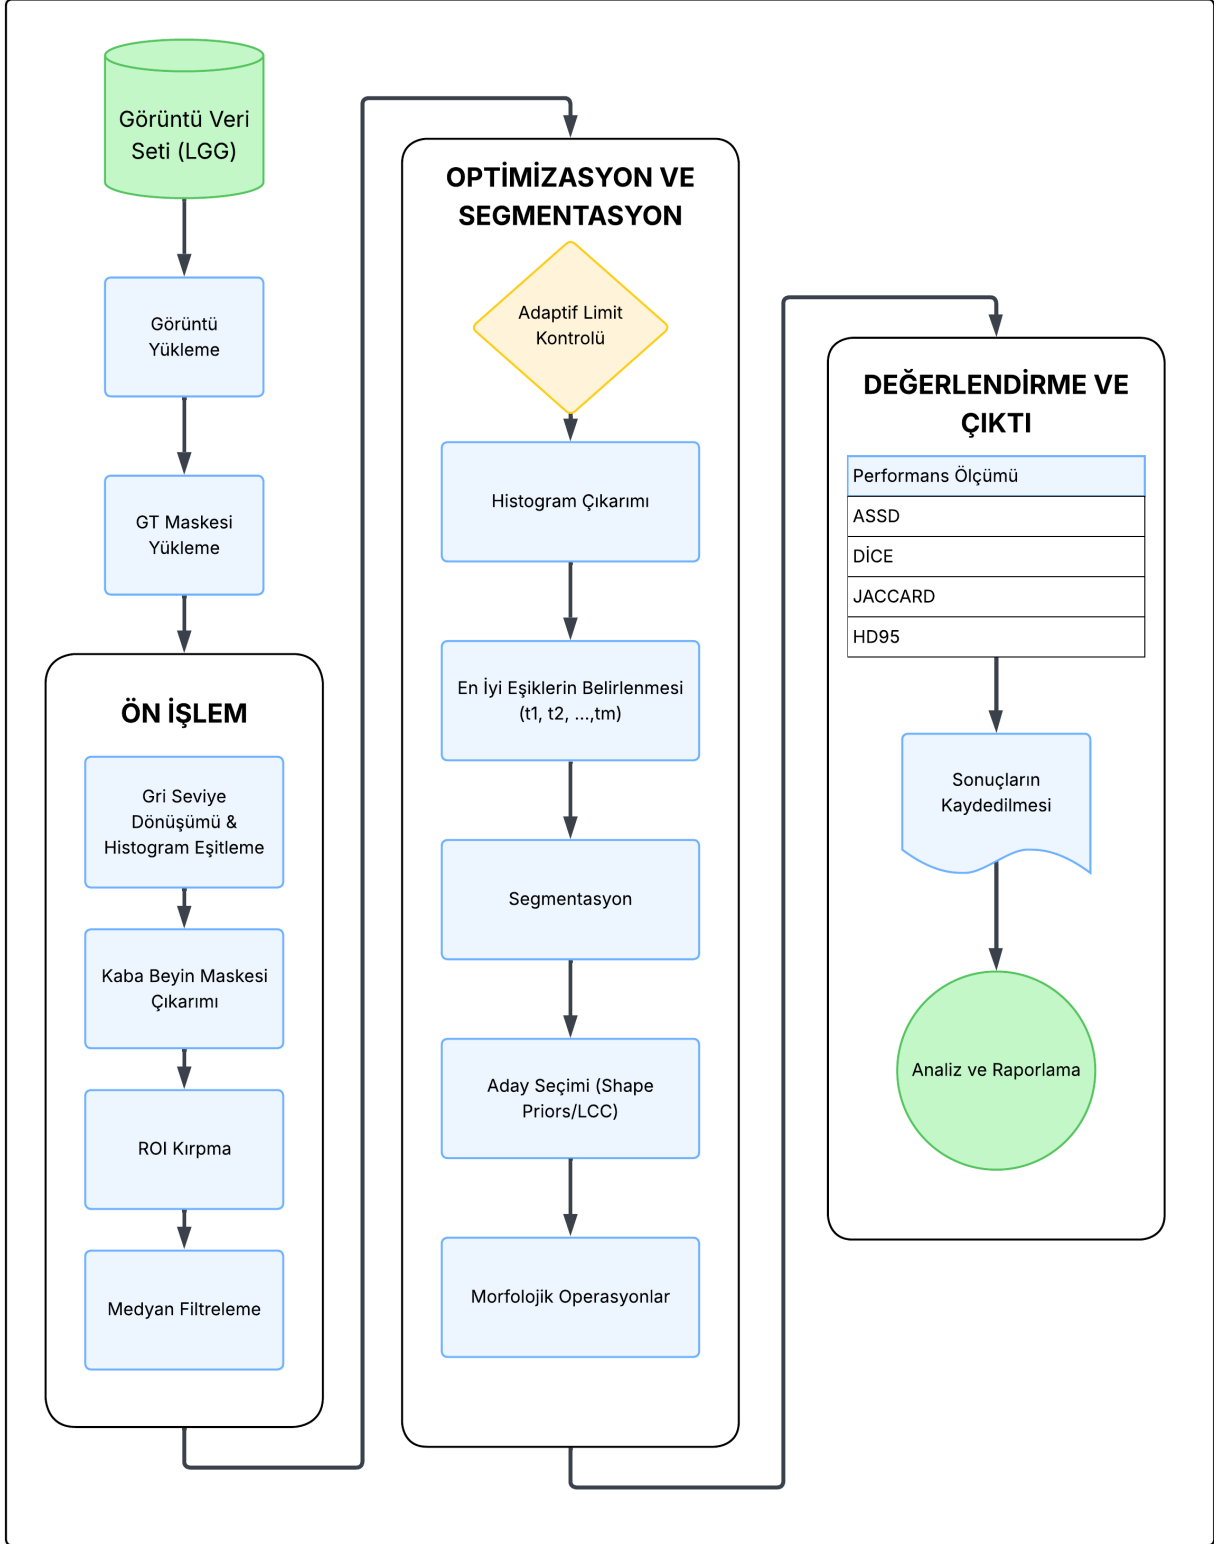
Önerilen sistem, tıbbi görüntülerdeki patolojik yapıların otomatik tespiti için dört ana modülden oluşan entegre bir mimari sunmaktadır. Süreç, ham MR verilerinin DICOM formatında sisteme yüklenmesi ve ardından gürültü giderme, kontrast iyileştirme gibi adımları içeren ön işleme aşamasıyla başlar. Sistemin çekirdeğini oluşturan optimizasyon modülünde, Otsu ve Kapur yöntemlerinin avantajlarını birleştiren hibrit bir amaç fonksiyonu, meta-sezgisel algoritmalar aracılığıyla maksimize edilerek en uygun eşik değerleri belirlenir. Son aşamada ise elde edilen segmentasyon maskeleri, yer-gerçek verileriyle karşılaştırılarak hem istatistiksel hem de mesafe tabanlı metrikler üzerinden valide edilir.

3.1. Önerilen Sistemin Mimarisi

Bu çalışmada önerilen çok seviyeli eşikleme tabanlı tümör segmentasyon sisteminin genel akış diyagramı Şekil 3.1’de sunulmuştur. Sistem; görüntü yükleme ve ön işleme, optimizasyon ve segmentasyon ve performans değerlendirme olmak üzere dört ana modülden oluşmaktadır.

Önerilen sistem, tıbbi görüntülerdeki patolojik yapıların otomatik tespiti için dört ana modülden oluşan entegre bir mimari sunmaktadır. Süreç, ham MR verilerinin DICOM formatında sisteme yüklenmesi ve ardından gürültü giderme, kontrast iyileştirme gibi adımları içeren ön işleme aşamasıyla başlar. Sistemin çekirdeğini oluşturan optimizasyon modülünde, Otsu, Kapur ve Renyi yöntemlerinin avantajlarını birleştiren hibrit bir amaç fonksiyonu, meta-sezgisel algoritmalar aracılığıyla maksimize edilerek en uygun eşik değerleri belirlenir. Son aşamada ise elde edilen segmentasyon maskeleri, yer-gerçek verileriyle karşılaştırılarak hem istatistiksel hem de mesafe tabanlı metrikler üzerinden valide edilir.

Geliştirilen bu mimari, hesaplama yükünü optimize etmek ve yüksek çözünürlüklü görüntüleri etkin bir şekilde işleyebilmek adına Python tabanlı modüler bir yazılım altyapısı üzerine inşa edilmiştir. Görüntü işleme kütüphaneleri (OpenCV, NumPy) ile matematiksel modelleme araçlarının entegre edildiği sistemde, çok seviyeli eşikleme işlemi sırasında oluşan yoğun hesaplama gereksinimi, GPU tabanlı paralel işlem yetenekleri (CUDA) kullanılarak karşılanmaktadır. Özellikle arama uzayının genişlediği yüksek eşik seviyelerinde, algoritmaların yakınsama hızını artırmak ve işlem süresini minimize etmek amacıyla vektörel hesaplama teknikleri uygulanmış; böylece klinik uygulamalarda ihtiyaç duyulan makul sürelerde sonuç üretilmesi hedeflenmiştir.




Şekil 3.1. Akış diyagramı


3.2. Veri Seti

Bu çalışmada, TCIA TCGA-LGG (tümör/ödem) koleksiyonunun (Sürüm 3) (Pedano vd., 2016) ameliyat öncesi beyin MRG görüntülerinden oluşan FLAIR alt kümesi kullanılmıştır. Birden fazla merkezden toplanan ve anonimleştirilmiş bu koleksiyon, DICOM formatındaki


görüntülerden oluşmakta ve TCIA'nın anonimleştirme, lisanslama ve atıf ilkelerine (Clark vd., 2013; The Cancer Imaging Archive (TCIA), 2025) uymaktadır. Çalışmaya dahil edilme kriteri olarak, olguların FLAIR sekansına sahip olması zorunluluğu aranmıştır. Bu kritere uyan 7856 görüntü arasından; eksik/bozuk dilimler, ağır görüntü bozulmaları veya tutarsız meta veriler gibi kalite ve bütünlük sorunları açısından incelenmiştir. Bu kontroller sonucunda 78 görüntü analize uygun bulunmuştur. Tüm olgulardaki FLAIR anormallik bölgeleri (tümör ve ödem dahil), tek bir değerlendirici tarafından her dilim için manuel olarak çizilmiştir. Bu çizimler, çalışma kapsamında referans (temel gerçek) maskeleri oluşturmak için kullanılmıştır. Veri setine erişim ve atıf, koleksiyona ait DOI kaydı üzerinden sağlanmış olup, arşivin genel tanımı ve kullanım ilkeleri ilgili kaynaklarda belirtilmiştir.




(a) Hasta 1




(b) Hasta 2




(c) Hasta 3



(d) Hasta 4



(e) Hasta 5



(f) Hasta 6

Şekil 3.2. TCIA-LGG veri setinden seçilen farklı hastalara ait kesit örnekleri.

3.3. Meta-Sezgisel Algoritmalar

Çok seviyeli eşikleme problemi, eşik sayısı arttıkça arama uzayının üstel olarak genişlemesi nedeniyle NP-zor kategorisinde değerlendirilmektedir. Bu karmaşıklığı aşmak için çalışmada, çözüm uzayını rastgelelik ve belirli kurallar çerçevesinde etkin bir şekilde tarayan doğa esinli algoritmalar tercih edilmiştir. Yapılan performans ön değerlendirmeleri sonucunda, düşük yakınsama kararlılığı gösteren Diferansiyel Evrim (DE), Ateş Böceği (FFA), Balina (WOA) ve Savaş Stratejisi (WSOA) algoritmaları elenmiş; süreç en yüksek kararlılığı sergileyen Parçacık Sürüsü Optimizasyonu (PSO) ve Guguk Kuşu Araması (CS) algoritmaları üzerine kurgulanmıştır. Bu algoritmalar, global keşif ve yerel sömürü dengesini kurarak hibrit fitness fonksiyonu için optimum eşik vektörlerini başarıyla tespit etmektedir.

3.3.1. Guguk kuşu arama optimizasyon algoritması

Guguk kuşu algoritması (Yang ve Deb, 2009) Yang tarafından önerilen bir optimizasyon yöntemi olup bu yöntem Levy uçuşuna dayanmaktadır ve Levy uçuşu çözüm alanındaki hızlı ve ani dönüşler ve uzun adımlarla geniş bir arama sağlar. Cuckoo kuşu yeni bir yuva bulup oraya yumurta bırakırken Levy uçuşu gerçekleştirir böylece bu durumda yeni bir çözüm bulunur ve var olan çözümlerden rastgele biriyle karşılaştırılır. En iyisi kalır diğeri ise atılır çünkü daha sonra, en iyi çözümler doğrudan bir sonraki nesile taşınır ve bu durum çözüm sürecinin daha hızlı ve sağlam olmasını sağlar. Ayrıca düşük kaliteli çözümler belirli bir oranda havuzdan çıkarılır ve bunun yerine yeni çözümler eklenir, çünkü bu durum çözüm sürecinin yerel optimumlarda durmamasını sağlar ve çözüm alanının daha geniş alanını keşfetmesini sağlar.

Algoritma 1 Lévy Uçuşları ile Guguk Kuşu Araması (Cuckoo Search)

- 1: **Girdi:** Amaç fonksiyonu $f(\mathbf{x})$, $\mathbf{x} = (x_1, x_2, \dots, x_d)$
 - 2: **Başlangıç:** n adet ev sahibi yuva içeren başlangıç popülasyonunu üret \mathbf{x}_i , $i = 1, 2, \dots, n$
 - 3: **while** ($t < \text{MaxGeneration}$) veya (durma kriteri sağlanmadı) **do**
 - 4: Lévy uçuşları ile bir guguk kuşu \mathbf{x}_{new} üret
 - 5: Uygunluğunu değerlendir $F_i = f(\mathbf{x}_{\text{new}})$
 - 6: n yuva arasından rastgele bir yuva \mathbf{x}_j seç
 - 7: **if** $F_i > F_j$ **then**
 - 8: \mathbf{x}_j 'yi \mathbf{x}_{new} ile değiştir
 - 9: **end if**
 - 10: En kötü yuvaların p_a oranındaki kısmını terk et ve yenilerini kur
 - 11: En iyi çözümleri (kaliteli yuvaları) sakla
 - 12: Çözümleri sırala ve mevcut en iyiyi güncelle
 - 13: **end while**
 - 14: **Çıktı:** Bulunan en iyi çözüm
-

3.3.2. Parçacık sürüsü optimizasyon algoritması

Parçacık Sürüsü Optimizasyonu algoritması (Kennedy ve Eberhart, 1995) temelinde, kuş sürülerinin ve balık okullarının sosyal davranışlarından esinlenerek geliştirilen ve sürü zekası prensiplerine dayanan popülasyon tabanlı stokastik bir optimizasyon tekniğidir. Algoritmanın temel işleyiş mekanizmasında, arama uzayındaki her bir parçacık bir aday çözümü temsil eder ve bu parçacıklar hem kendi kişisel deneyimlerinden elde ettikleri en iyi konumu hem de sürünün o ana kadar bulduğu global en iyi konumu referans alarak hız vektörlerini ve pozisyonlarını günceller. Tez çalışması kapsamında bu algoritma, özellikle hızlı yakınsama yeteneği ve düşük hesaplama maliyeti sunması nedeniyle tercih edilmiş olup, arama sürecinin dinamiklerini optimize etmek amacıyla sabit bir atalet ağırlığı yerine iterasyonlar ilerledikçe lineer olarak azalan dinamik bir strateji kullanılmıştır. Başlangıç aşamasında yüksek tutulan atalet ağırlığı algoritmanın global keşif yeteneğini artırırken, sürecin sonuna doğru düşürülen ağırlık değeri yerel arama hassasiyetini güçlendirerek çözümün optimum noktaya daha kararlı bir şekilde yerleşmesini sağlamıştır. Bilişsel ve sosyal öğrenme katsayılarının eşit ve sabit bir değerde tutulduğu bu yapılandırma sayesinde, algoritma Guguk Kuşu yöntemine kıyasla çok daha az sayıda fonksiyon değerlendirmesi yaparak sonuca ulaşmış ve işlemsel verimlilik açısından üstün bir performans sergilemiştir

Algoritma 2 Particle Swarm Optimization (PSO)

- 1: **Input:** Objective function $f(\mathbf{x})$, $\mathbf{x} = (x_1, \dots, x_d)$
 - 2: **Initialize:** Initialize a swarm of n particles with random positions \mathbf{x}_i and velocities \mathbf{v}_i
 - 3: Evaluate the fitness $f(\mathbf{x}_i)$ for each particle
 - 4: Initialize personal best positions $\mathbf{p}_i \leftarrow \mathbf{x}_i$
 - 5: Determine global best position \mathbf{g}
 - 6: **while** stopping criterion not met **do**
 - 7: **for** each particle $i = 1$ to n **do**
 - 8: Update velocity:
 $\mathbf{v}_i \leftarrow w \cdot \mathbf{v}_i + c_1 \cdot r_1 \cdot (\mathbf{p}_i - \mathbf{x}_i) + c_2 \cdot r_2 \cdot (\mathbf{g} - \mathbf{x}_i)$
 - 9: Update position: $\mathbf{x}_i \leftarrow \mathbf{x}_i + \mathbf{v}_i$
 - 10: Evaluate new fitness $f(\mathbf{x}_i)$
 - 11: **if** $f(\mathbf{x}_i) < f(\mathbf{p}_i)$ **then**
 - 12: $\mathbf{p}_i \leftarrow \mathbf{x}_i$
 - 13: **end if**
 - 14: **if** $f(\mathbf{p}_i) < f(\mathbf{g})$ **then**
 - 15: $\mathbf{g} \leftarrow \mathbf{p}_i$
 - 16: **end if**
 - 17: **end for**
 - 18: **end while**
 - 19: **Output:** Global best solution \mathbf{g}
-

3.4. Görüntü Eşikleme Algoritmaları

Görüntü eşikleme algoritmaları, görüntü segmentasyonu işleminde optimizasyon temelli, entropi tabanlı, istatistiksel, veya fiziksel model tabanlı yöntemler ile eşikleme gerçekleştirilmektedir. Görüntü işleme uygulamalarında, piksel parlaklık düzeylerinin (gri tonlamalı) veya renk bileşenlerinin istatistiksel dağılımlarını analiz edebilmek için, bu değerlerin frekanslarına dayalı histogram temsili oluşturulmaktadır. Ortaya çıkan istatistiksel veri, görüntüdeki nesne ve arka plan bölgelerinin ayrıştırılmasında kullanılan eşikleme algoritmalarının başlangıç adımını oluşturmaktadır. Bu algoritmaların kullanım amaçları, görüntüdeki anlamlı bölgeleri tanımlamak, sınıflandırmak ve daha ileri analizler için uygun yapısal ayrımlar oluşturmaktır.

3.4.1. Otsu yöntemi

Otsu metodu (Otsu, 1979), gri tonlamalı görüntülerde nesne ve arka plan bölgelerini birbirinden ayırmak amacıyla otomatik eşikleme gerçekleştiren, istatistiksel temelli bir görüntü işleme tekniğidir. Yöntemin hedefi, eşik değeri ile bölünen iki sınıf arasındaki ayrımı maksimize etmektir. Otsu'nun çalışma prensibi eşik değerini, ile verilen sınıflar arası varyansı maksimize edecek şekilde seçmeyi önermektedir. Bu varyans, her iki sınıfın ortalamalarının toplam görüntü ortalamasından uzaklıklarının ağırlıklı kareleriyle hesaplanır. Görüntünün histogramı üzerinden olasılık dağılımı elde edilerek, tüm olası eşik değerleri için bu ölçüt hesaplanır maksimum değeri sağlayan eşik, optimal eşik olarak belirlenir. Otsu'nun önerdiği bu yöntem, histogramın iki belirgin tepeye sahip olduğu, yani nesne ve arka planın istatistiksel olarak ayrık olduğu durumlarda yüksek doğrulukta segmentasyon sağlamaktadır. Otsu metodu belirli varsayımlar altında çalışmaktadır. Histogramda iki sınıfın ayrımının net olmadığı, sınıflar arası yoğunluk farkının düşük olduğu veya gürültü sebebiyle histogramın düz ve geniş vadilere sahip olduğu durumlarda, optimal eşik değeri belirleme konusunda yetersizlikler ortaya çıkabilir. Sınıflardan birinin varyansının diğerine kıyasla oldukça büyük olması durumunda, eşik değeri bu baskın sınıfın istatistiksel özellikleri doğrultusunda belirlenmekte ve bu durum segmentasyon kalitesini olumsuz etkileyebilmektedir. Çok seviyeli eşikleme uygulamalarında ise yöntem, sınıflar arası toplam varyansı maksimize edecek şekilde birden fazla eşik değeri hesaplayarak, görüntüyü çoklu bölgelere ayırmak için genelleştirilebilir.

3.4.2. Kapur yöntemi

Kapur'un entropi tabanlı eşikleme yöntemi (Kapur vd., 1985), görüntü segmentasyonunda bilgi kuramına dayalı bir yaklaşımdır. Kapur yöntemi bir görüntünün histogramını kullanarak, arka plan ve nesne sınıflarının olasılık dağılımları üzerinden her bir sınıfa ait entropi değerlerini hesaplar. Kapur yöntemi, iki veya daha fazla sınıfa ayrılacak şekilde toplam entropiyi maksimize eden eşik değerini seçerek optimal bölütleme sağlar. İkili eşikleme durumunda, toplam entropi ifadesiyle tanımlanırken, çok seviyeli eşikleme için bu toplam şeklinde genişletilebilir. Kapur yönteminde çıkan yüksek entropi değeri, görüntüdeki bilgi içeriğinin daha homojen ve anlamlı bir şekilde ayrıldığını gösterir. Kapur metodu çalışmasında, gri tonlamalı değerlerinin

görelî frekanslarıyla tanımlanan olasılık dağılımlarına dayalı bilgi ölçümü yer almaktadır. Kapur yöntemi, görüntüdeki her bölgenin entropisini hesaplayarak bu bölgelerin içerdiği bilgi miktarını ölçer; dolayısıyla, segmentasyon kalitesi doğrudan toplam entropi ile ilişkilidir. Bu özelliği sayesinde, Kapur'un entropi yöntemi, özellikle karmaşık dağılımlara sahip görüntülerde yüksek doğrulukla segmentasyon gerçekleştirebilmekte ve pek çok optimizasyon algoritmasıyla entegre edilerek otomatik çoklu eşikleme problemlerine çözüm sunmaktadır. Kapur metodu çok seviyeli eşiklemeye uygun olmaktadır. Metodun çok seviyeli çalışma biçimi görüntü T+1 bölgeye ayrılır ve toplam entropi her bir bölgenin entropilerinin toplamı olarak hesaplanır. Kapur ölçütü, histogramdaki sınıflara karşılık gelen tepeler arasındaki vadi noktalarında toplam entropiyi en yüksek değere taşır; böylece seçilen eşikler, sınıflar arasındaki bilgi ayrımını doğrudan enformasyon kuramı perspektifiyle en iyi hâle getirir.

3.4.3. Rényi yöntemi

Rényi yöntemi (Rényi, 1961; Sahoo vd., 1997), görüntü eşikleme için bilgi kuramını temel alan bir başka genelleştirilmiş entropi ölçüsünü kullanır. Tıpkı Kapur ve Tsallis yöntemleri gibi, Rényi'nin yaklaşımı da görüntüyü arka plan ve nesne olarak iki sınıfa ayırır ve bu iki sınıfın toplam entropisini maksimize etmeyi amaçlar. Bu yöntemin temel farkı, entropi hesaplaması için Rényi entropisi adı verilen farklı bir formülasyonu kullanmasıdır.

Bu yöntemin temel taşı, alfa (α) olarak adlandırılan bir parametredir. "Entropi sırası" olarak da bilinen bu alfa parametresi, yöntemin histogramın olasılık dağılımına nasıl tepki vereceğini ayarlar. Tsallis'in q parametresine benzer şekilde, alfa da yöntemde esneklik katar. Alfa parametresinin değeri, segmentasyonun doğasını değiştirir. Çok özel bir durum olarak, alfa parametresinin değeri 1'e yaklaştığında, Rényi entropisi, Kapur yönteminin kullandığı standart Shannon entropisi ile aynı davranışı gösterir. Bu nedenle Rényi yöntemi de Kapur'un entropi yönteminin bir genellemesi olarak kabul edilebilir. Uygulamada, alfa için 1'den farklı değerler seçilerek, histogramın farklı özelliklerine vurgu yapılması sağlanır. Daha yüksek alfa değerleri, histogramdaki daha yüksek olasılıklara daha fazla ağırlık verme eğilimindeyken, daha düşük değerler daha nadir piksellere karşı daha hassas olabilir. Bu esneklik, yöntemin farklı gürültü seviyelerine veya belirsiz histogramlara sahip görüntülerde daha iyi sonuçlar vermesini sağlayabilir. Optimal eşik değeri, her iki sınıf için arka plan ve nesne hesaplanan toplam Rényi entropisini en yüksek değere ulaştıran gri seviye değeri olarak seçilir. Tsallis ve Kapur yöntemlerinde olduğu gibi, Rényi yöntemi de görüntüyü ikiden fazla bölgeye ayırmak için çok seviyeli eşikleme problemlerine kolayca genelleştirilebilir.

3.5. Ön İşleme

MR görüntülerinde yoğunluk ölçüğü cihaz ve çekim parametrelerine duyarlı olduğundan (Nyúl ve Udupa, 1999), tüm FLAIR dilimleri tek kanallı 8-bit gri seviye aralığına lineer olarak dönüştürülmüş ve analiz bu uzayda yürütülmüştür. Beyin içi bölgeyi sınırlamak için ikili bir "kaba beyin maskesi" elde edilmiş, maskeden türetilen eksen-hizalı kırpma kutusu (bounding box) ile görüntü ve maske ROI'ye (İlgi Alanı) indirgenmiştir. Sınır belirsizliklerini azaltmak

amacıyla maske fiziksel uzayda $4mm$ morfolojik erozyona uğratılmış (Soille, 2004), izotropik olmayan piksel aralıklarında yapı elemanı eliptik tanımlanarak erozyon mesafesi korunmuştur. Tüm ölçümler ve kararlar bu “iç ROI” üzerinde gerçekleştirilmiştir.

Yoğunluk ölçeğini kararlı ve eşik aramaya elverişli kılmak için ROI içinde global histogram eşitleme uygulanmış (Gonzalez ve Woods, 2008), kümülatif dağılım fonksiyonuna (CDF) dayalı monoton dönüşümle piksel sırası korunarak etkin dinamik aralık genişletilmiştir. Eşitleme sonrasında, aşırı parlak piksellerin amaç yüzeyini bozmasını önlemek üzere ROI'nin üst kuyruğunda yüzdelik tabanlı kırpma uygulanmış; eşik yüzdesi adaptif olarak $[98.5, 99.8]$ aralığında seçilmiş ve en az %3 kırpma garantisi edilmiştir. Böylece uç değerlerin etkisi sınırlandırılmış ve yoğunluk ölçeği daha kararlı hale getirilmiştir. Ardından ROI histogramı 256 kovada çıkarılmış, eşik adayları $[1, 254]$ bandında ve minimum aralık kısıtı ile tanımlanmıştır. Dinamik aralığın genişlemesi, Otsu'nun sınıf içi varyans minimizasyonu ve Kapur'un sınıf entropileri için keskin ve gürültüye duyarlı tepe oluşumlarını yatıştırarak amaç yüzeyinin daha düzenli örneklenmesine katkı sağlamaktadır.

Köşe durumları için süreç esneklik: ROI doğal olarak yüksek kontrastlı ise eşitleme dönüşümü özdeşliğe yakın çalışır ve etkisi sınırlı kalır; doygunluk oranı yükseldiğinde adaptif üst-kuyruk yüzdesi otomatik düşürülerek CDF'nin sonundaki plato baskılanır. Kaba beyin maskesi boş üretildiğinde ROI tüm görüntüye genişletilir ve erozyon adımı devre dışı kalır.

3.6. Çoklu Eşik Optimizasyonu

Görüntü bölütleme sürecinde aranan eşik sayısı arttıkça, taranması gereken olası çözüm kombinasyonlarının üstel bir artış göstermesi, problemi geleneksel deterministik yöntemlerle makul sürede çözülemeyen NP-Zor (Non-deterministic Polynomial-time hard) sınıfına sokmaktadır. Ayrıca, MR görüntülerinin içerdiği gürültü ve doku çeşitliliği nedeniyle oluşan karmaşık ve çok tepeli histogram yapısı, türev tabanlı klasik yöntemlerin global en iyi çözüm yerine yerel optimum tuzaklarına düşmesine neden olmaktadır. Bu hesaplama zorluklarını aşmak amacıyla, geniş arama uzayını stokastik süreçlerle tarayarak global keşif ve yerel sömürü dengesini kurabilen Parçacık Sürüsü ve Guguk Kuşu gibi meta-sezgisel algoritmaların kullanımı, yüksek doğruluklu ve maliyet-etkin bir segmentasyon için tercih edilmiştir.

İlgi alanı (ROI) içinde gri-seviye histogramı $L = 256$ seviye üzerinden $p(i)$ ile tanımlanır. $p(i)$ bir olasılık dağılımı olduğundan toplamsallık koşulunu sağlar:

$$\sum_{i=0}^{L-1} p(i) = 1 \quad (D.1)$$

Çok seviyeli eşikleme için m adet eşik vektörü, sıralı kısıtlama ile aşağıdaki gibi tanımlanır:

$$T = \{t_1, t_2, \dots, t_m\}, \quad 0 \leq t_1 < t_2 < \dots < t_m < L - 1 \quad (D.2)$$

Bu eşikler, yoğunluk eksenini $m + 1$ ayrıık sınıfa böler; uçlar dahil parçalama aşağıdaki kümelerle ifade edilir:

$$C_0 = [0, t_1], \quad C_1 = [t_1 + 1, t_2], \quad \dots, \quad C_m = [t_m + 1, L - 1] \quad (D.3)$$

Her sınıfın kütlesi (olasılık ağırlığı) histogramdan toplanır:

$$\omega_k = \sum_{i \in C_k} p(i) \quad (D.4)$$

Sınıf içindeki koşullu dağılım bölme kuralıyla tanımlanır; $\omega_k = 0$ durumunda sayısal kararlılık için $q_k(i)$ sıfırlanır:

$$q_k(i) = \frac{p(i)}{\omega_k}, \quad i \in C_k \quad (D.5)$$

Buna göre sınıf ortalaması (μ_k) ve global ortalama (μ_G) şu şekilde yazılır:

$$\mu_k = \sum_{i \in C_k} i \cdot q_k(i), \quad \mu_G = \sum_{i=0}^{L-1} i \cdot p(i) \quad (D.6)$$

Böylece Otsu'nun sınıflar arası varyans ölçütü ile Kapur ve Rényi'nin entropi-tabanlı amaç fonksiyonlarının çoklu-eşik sürümleri için gerekli temel büyüklükler tutarlı biçimde elde edilmiş olur.

Otsu (Sınıflar Arası Ayrımın Artırılması): Çoklu eşiklemede Otsu ölçütü, sınıflar arası varyansı maksimize eder. Bu, tek eşikli formun $m + 1$ sınıfa doğrudan genellemesidir ve büyük sınıflara daha fazla ağırlık vererek ayrışmayı ölçer:

$$f_{Otsu}(T) = \sum_{k=0}^m \omega_k (\mu_k - \mu_G)^2 \quad (D.7)$$

Kapur (Sınıf İçi Belirsizliğin Azaltılması): Kapur yaklaşımı, her sınıfın Shannon entropilerini toplayıp maksimize eder. Logaritmanın tabanı argümanı etkilemez; amaç sınıf içi dağılımları “bilgi-zengin” ve homojen kılmaktır:

$$f_{Kapur}(T) = \sum_{k=0}^m \left(- \sum_{i \in C_k} q_k(i) \ln q_k(i) \right) \quad (D.8)$$

Rényi (Parametrik Entropi Genellemesi): Rényi entropisi, $\alpha > 0, \alpha \neq 1$ için aşağıdaki biçimdedir ve $\alpha \rightarrow 1$ limitinde Shannon entropisine yaklaşır. Bu çalışmada $\alpha = 1.1$ seçilerek sınıf içi sivriliğe duyarlılık artırılmıştır:

$$f_{Renyi}(T) = \sum_{k=0}^m \left(\frac{1}{1 - \alpha} \ln \sum_{i \in C_k} (q_k(i))^\alpha \right) \quad (D.9)$$

Hibrit Entropi: Sınıf içi düzen ile varyans (sınıflar arası ayırım) sinyallerini birlikte kullanmak için ölçek-uyumlu bir hibrit amaç tanımlanır. Bileşenler popülasyon içi min–maks ile $[0, 1]$ aralığına normalize edilip ağırlıklı toplanır:

$$f_{Hybrid}(T) = \lambda_O \bar{f}_{Otsu}(T) + \lambda_K \bar{f}_{Kapur}(T) + \lambda_R \bar{f}_{Renyi}(T) \quad (D.10)$$

Burada λ değerleri $\lambda_O, \lambda_K, \lambda_R \geq 0$ ve toplamları 1'dir. Bu normalizasyon, ölçütlerin büyüklük farklarından doğan ölçek sapmasını gidererek meta-sezgisellerde dengesiz keşif-sömürü davranışını azaltır.

Erişilebilirlik Uzayı ve Başlatma: Boş veya dejenere sınıfları engellemek için erişilebilirlik uzayı aşağıdaki gibi kısıtlanır:

$$t_{k+1} - t_k \geq g, \quad (g \geq 3) \quad (D.11)$$

Başlangıç eşikleri, ROI kümülatif dağılım fonksiyonunun (CDF) eşit-kuantil noktalarından alınarak sınıf piksel oranları dengelenir ve eşikleme yüzeyindeki keskin gürültüye duyarlı tepeler yatıştırılır. Sonuçta çözüm olarak en iyi eşik vektörü T^* bulunur; deterministik tohumla yapılan çoklu tekrarlar, aynı koşullarda en iyi sonucun seçilmesini sağlar:

$$T^* = \arg \max_T f_{Hybrid}(T) \quad (D.12)$$

3.7. Sınıf Haritalama ve Bölütleme

Optimizasyon süreci sonucunda elde edilen eşik vektörü $T = (t_1, \dots, t_m)$, ROI içindeki her pikseli gri-seviye değerine göre $m + 1$ sınıftan birine atamak için kullanılır. Yoğunluk eksenini, $\tau_0 = 0$ ve $\tau_{m+1} = 255$ olmak üzere $\tau_k = t_k$ sınırlarıyla parçalanarak sınıf indeksi (k) aşağıdaki biçimde tanımlanır:

$$k(r, c) = j, \quad \text{eğer } \tau_j \leq I(r, c) < \tau_{j+1} \quad (D.13)$$

Böylece $\ell : ROI \rightarrow \{0, \dots, m\}$ tam sayı değerli bir sınıf haritası üretilir. Görselleştirmede $\{\tau_k\}$ dikey çizgilerle gösterilse de, asıl bölütleme işlemi sınıf etiketlerinden türetilen aday ikili bileşenler üzerinden yürütülür. Aday üretimi ve seçim işlemleri aşağıdaki adımlarla gerçekleştirilir:

(i) Aday Üretimi: ROI üzerinde 8-komşuluklu bağlantılı bileşen etiketleme (Rosenfeld–Pfaltz iki aşamalı şemanın modern türevleri) uygulanarak her sınıf için ikili adaylar çıkarılır ve ROI dışı pikseller elenir.

(ii) Sınır Kalitesi Ölçümü: Sınır kalitesini kararlı biçimde ölçmek için Sobel türevlerinden gradyan büyüklüğü (G) hesaplanır. Uç değerlerin etkisini bastırmak üzere, gradyan haritası

99.5'inci yüzdelik değer ($p_{99.5}$) ile normalize edilir:

$$\hat{G}(r, c) = \min \left(\frac{\sqrt{G_x^2 + G_y^2}}{p_{99.5}}, 1 \right) \quad (\text{D.14})$$

Bu işlemle sınırdaki beklenen yüksek gradyanlar $[0, 1]$ ölçeğine çekilmiş olur.

(iii) Alan Filtreleme: Ölçekten bağımsız bir asgari nesne payı ile çok küçük gürültü parçaları elenir. ROI alanı $A_{ROI} = |\{(r, c) \mid \text{mask}(r, c) = 1\}|$ olmak üzere, aşağıdaki koşulu sağlamayan bileşenler atılır:

$$\frac{|C|}{A_{ROI}} \geq \epsilon_{min} \quad (\text{D.15})$$

(iv) Puanlama: Kalan her aday C için; sınır gradyanı, iç homojenlik ve ROI oranını dengeleyen bir puan (S) tanımlanır:

$$S(C) = \alpha \cdot \bar{G}_{\partial C} + \beta \cdot (1 - \sigma_e(C)) + \gamma \cdot \frac{|C|}{A_{ROI}} \quad (\text{D.16})$$

Burada $\sigma_e(C)$, sınıf-içi yoğunluk standart sapmasının dinamik aralığa göre normalize edilmiş halidir.

(v) Seçim ve Maskeleyme: En yüksek puanlı tek bağlantılı bileşen C_b seçilir:

$$C_b = \arg \max_C S(C) \quad (\text{D.17})$$

Seçilen bileşen ROI'den tüm görüntü boyutuna geri yerleştirilir. Son maske, anatomik kısıtları uygulamak için kaba beyin maskesi B ve erozyonla daraltılmış iç beyin maskesi B_{int} ile kesiştirilir. Böylece beyin dışına taşmalar ve sınırdaki belirsizlikler (morfolojik erozyon ve maskeleyme sınırlama) bastırılır.

Çıktı alanı çok küçükse, seçim işlemi Eşitlik D.16'daki gradyan ağırlığı azaltılarak ($\alpha \downarrow$) ve eşikler sabit tutularak yinelenir. Bu gevşetme stratejisi, zayıf kenar ya da düşük kontrast koşullarında istikrarlı tek-bileşen seçimini kolaylaştırır. Normalizasyon ve yüzdelik kırpmada tercihleri, MR yoğunluk ölçeğindeki cihaz/protokol değişkenliğine karşı yaygınlaştırılmış dayanıklılık sağlar.

Çok seviyeli eşikleme problemi, gri seviye histogramı üzerinde tanımlı bir kombinatoriyal optimizasyon problemi olarak modellenmiştir. Geleneksel yaklaşımların aksine, Parçacık Sürüsü Optimizasyonu ve Guguk Kuşu Araması algoritmalarındaki her bir birey, tekil bir sayısal değeri değil, görüntüyü $m + 1$ sınıfa ayıracak olan m boyutlu bir eşik vektörünü ($T = \{t_1, t_2, \dots, t_m\}$) temsil etmektedir. Arama uzayı, görüntüdeki piksel yoğunluk değerleri olan $[1]$ aralığı ile sınırlandırılmış olup, çözüm vektörlerinin geçerliliği için $t_1 < t_2 < \dots < t_m$ sıralama kısıtı ve eşikler arasında minimum 3 piksel mesafe ($|t_i - t_{i+1}| \geq 3$) koşulu uygulanmıştır. Algoritmalar,

bu kısıtlar altında Eşitlik 3.10'da tanımlanan hibrit amaç fonksiyonunu maksimize eden vektör konumlarını aramak üzere kurgulanmıştır.

Standart PSO algoritması, MR görüntülerinin çok tepeli ve karmaşık histogram yapısında erken yakınsama riski taşımaktadır. Bu riski minimize etmek ve arama sürecinin dinamiklerini optimize etmek amacıyla, çalışmada dinamik atalet ağırlığı stratejisi benimsenmiştir. Bu yaklaşımda, parçacığın önceki hızını koruma eğilimini ifade eden atalet ağırlığı, iterasyonların başında $w = 0.72$ seviyesinde tutularak parçacıkların histogram üzerinde geniş bir alana yayılması ve global keşif yapması sağlanmıştır. Süreç ilerledikçe bu değer lineer olarak $w = 0.36$ 'ya düşürülerek, bulunan potansiyel tepe noktaları etrafında hassas sömürü yapılması hedeflenmiştir. Parçacıkların bireysel ve sürü tecrübelerine yönelimini sağlayan bilişsel ve sosyal öğrenme katsayıları ise, arama dengesini korumak adına 1.6 olarak sabitlenmiştir.

CS algoritması, özellikle tümörlü dokuların neden olduğu karmaşık histogram dağılımlarında yerel optimum tuzaklarından kurtulma yeteneği nedeniyle modele entegre edilmiştir. Bu algoritmanın segmentasyon problemine uygulanışındaki en kritik mekanizma, arama uzayında rastgele yürüyüş yerine uzun mesafeli sıçramalara olanak tanıyan Lévy Uçuşları yöntemidir. Çalışmada Lévy dağılım parametresi $\lambda = 1.5$ ve adım boyu katsayısı $\alpha = 0.01$ olarak ayarlanmıştır. Bu mekanizma sayesinde algoritma, histogram üzerindeki bir çözümden çok uzak bir noktadaki potansiyel çözüme aniden atlayabilmekte, böylece yanlış tepe noktalarında takılı kalma riski minimize edilmektedir. Ayrıca, popülasyon çeşitliliğini korumak adına her iterasyonda en kötü performansa sahip çözüm vektörlerinin %25'inin terk edilerek, yerlerine histogramın rastgele bölgelerinden yeni aday eşik vektörlerinin üretilmesi sağlanmıştır.

Her iki algoritma için de başlatma aşamasında, popülasyonun histogramın yoğun olduğu bölgelere odaklanmasını sağlamak ve yakınsama hızını artırmak amacıyla, tamamen rastgele dağılım yerine histogramın Kümülatif Dağılım Fonksiyonu üzerinden belirlenen kuantil noktaları kullanılarak başlatma stratejisi izlenmiştir.

3.8. Başarım Ölçütleri ve Değerlendirme

Geliştirilen segmentasyon yönteminin klinik geçerliliğini ve sayısal doğruluğunu ölçmek amacıyla çok boyutlu bir değerlendirme protokolü uygulanmıştır. Bölütleme başarısının temel göstergesi olarak, tahmin edilen maske ile uzman çizimleri arasındaki örtüşmeyi ölçen Dice Benzerlik Katsayısı (DSC) ve Jaccard İndeksi (IoU) kullanılmıştır. Sadece alan tabanlı ölçümlerin yetersiz kaldığı durumlarda, tümör sınırlarının anatomik doğruluğunu belirlemek amacıyla Hausdorff Mesafesi (HD95) ve Ortalama Simetrik Yüzey Mesafesi (ASSD) gibi mesafe tabanlı metrikler devreye alınmıştır. Ayrıca, sınır hizasını piksel düzeyinde hassasiyetle değerlendiren Boundary-F1 skoru ve hacimsel hataları raporlayan RVD/AVD ölçütleri, sistemin performans spektrumunu tamamlamaktadır.

3.8.1. Performans ölçütleri

Değerlendirme yalnızca yer-gerçek (Ground Truth, GT) maskesi T mevcut olduğunda yapılmış; T yoksa tüm metrikler NaN olarak raporlanmıştır. Aşağıda kullanılan ölçütler, tanım

ve birim tutarlılığı sağlanacak biçimde verilmiştir. Yapılan ön testlerde DE, FFA, WSOA ve WOA algoritmalarının yakınsama başarısı düşük olduğundan detaylı analizler PSO ve CS ile sürdürülmüştür.

Alan/Örtüşme Doğruluğu — Dice: Tahmin maskesi Y için Dice benzerlik katsayısı (DSC), aşağıdaki gibi ((Taha ve Hanbury, 2015)) tanımlanır; sınıf dengesizliğine duyarlı olup küçük hedeflerde küçük farkları büyütebilir:

$$DSC(Y, T) = \frac{2|Y \cap T|}{|Y| + |T|} \quad (D.18)$$

Sınır Hizası — Boundary-F1 (mm): Sınır tabanlı hassasiyet (P) ve duyarlılık (R), τ toleransında (mm) eşleşen sınır pikselleri üzerinden ((Arbeláez vd., 2011; Yeghiazaryan ve Voiculescu, 2018)) hesaplanır. $B(Y)$ ve $B(T)$ tahmin ve GT sınır kümeleri, $N_\tau(\cdot)$ ise fiziksel uzayda (mm) τ yarıçaplı komşuluk olsun. O halde:

$$P = \frac{|B(Y) \cap N_\tau(B(T))|}{|B(Y)|}, \quad R = \frac{|B(T) \cap N_\tau(B(Y))|}{|B(T)|} \quad (D.19)$$

Bu tanım alan etkisinden büyük ölçüde bağımsız olarak kontur hizasını ölçer. Tolerans $\tau = 2$ mm olarak kullanılmıştır. Piksel/voksel farkları fiziksel birime dönüştürülür (2B için z terimi yoktur). Sınır toleranslı F1 yaklaşımı ($2PR/(P+R)$) klasik sınır ölçütlerine (BDSX hattı) paraleldir ve medikal görüntüleme mm-uzayına genişletilerek kullanılmaktadır.

Yüzey Uzaklıkları — ASSD ve HD95 (mm): ∂Y ve ∂T yüzey/sınır noktaları olmak üzere, bir $y \in \partial Y$ noktasının ∂T 'ye en kısa mesafesi $d(y, \partial T) = \min_{t \in \partial T} \|y - t\|$ olsun. Ortalama Simetrik Yüzey Uzaklığı (ASSD) (Mehta vd., 2022; Nai vd., 2021) şu şekilde hesaplanır:

$$ASSD(Y, T) = \frac{1}{|\partial Y| + |\partial T|} \left(\sum_{y \in \partial Y} d(y, \partial T) + \sum_{t \in \partial T} d(t, \partial Y) \right) \quad (D.20)$$

Hausdorff'un 95. yüzdeliği (HD95), her iki yöndeki en yakın mesafe dağılımlarının 95. persentillerinin maksimumudur:

$$HD95(Y, T) = \max(P_{95}\{d(y, \partial T)\}, P_{95}\{d(t, \partial Y)\}) \quad (D.21)$$

HD95, tekil aykırılara karşı klasik Hausdorff'tan daha dayanıklıdır; BraTS ve pek çok zorlukta Dice ile birlikte raporlanır.

Hacimsel Tutarlılık — RVD ve AVD (%): İki boyutta alan (genelde hacim için aynı formül voksel hacmiyle geçerlidir) olmak üzere; bağıl hacim farkı (RVD) ve mutlak versiyonu (AVD) şu şekilde (Taha ve Hanbury, 2015) tanımlanır:

$$RVD = \frac{|Y| - |T|}{|T|}, \quad AVD = \frac{||Y| - |T||}{|T|} \quad (D.22)$$

RVD işaretli sapmayı, AVD ise büyüklüğü raporlar; klinik hacim ölçüm hatasıyla daha doğrudan ilişkilidir.

Lezyon Düzeyi Başarı (Lesion Precision/Recall/F1): GT ve tahmin maskeleri 3B bağlantılı bileşenlere ayrılır; bir tahmin lezyonu (L_Y) ile bir GT lezyonu (L_T), $IoU(L_Y, L_T) \geq \theta$ olduğunda eşleşmiş (Kuijf vd., 2019) sayılır. Eşleşmelerden lezyon düzeyinde kesinlik ve duyarlılık hesaplanır. Çalışmada küçük lezyonların kısmi yakalanmasını da değerlendirmek üzere $\theta = 0.10$ seçilmiştir; bu eşik WMH ve benzeri zorluklarda kullanılan lezyon-düzeyi eşleştirme prensipleriyle uyumludur.

Bu çalışmanın geliştirme aşamasında, önerilen hibrit amaç fonksiyonunun optimizasyonu için literatürde yaygın olarak kullanılan altı farklı meta-sezgisel algoritma (Guguk Kuşu (CS), Diferansiyel Evrim (DE), Ateş Böceği (FFA), Parçacık Sürüsü (PSO), Balina (WOA) ve Savaş Stratejisi (WSOA)) üzerinde kapsamlı pilot testler gerçekleştirilmiştir. LGG veri seti üzerinde yapılan bu ön deneysel çalışmalarda; DE, FFA, WOA ve WSOA algoritmalarının, problemin çok kipli yapısı karşısında yakınsama hızlarının düşük kaldığı ve yerel optimum noktalara takılarak segmentasyon başarımını (Dice skoru açısından) sınırladığı gözlemlenmiştir.

Buna karşın, Parçacık Sürüsü (PSO) ve Guguk Kuşu (CS) algoritmaları, hibrit entropi-varyans fonksiyonunu optimize etmede diğer yöntemlere kıyasla belirgin şekilde daha kararlı ve üstün bir performans sergilemiştir. Bu nedenle, çalışmanın bütünlüğünü korumak ve en başarılı sonuçları derinlemesine analiz edebilmek amacıyla; tezin sonraki aşamalarındaki detaylı performans değerlendirmeleri ve karşılaştırmalar, eleme sürecini başarıyla geçen bu iki temel algoritma (PSO ve CS) ile bunların hibrit varyasyonları üzerinden yürütülmüştür.

3.8.1.1. Grafiksel değerlendirme yöntemleri

Çalışma kapsamında elde edilen sayısal bulguların klinik geçerliliğini ve algoritmik davranışlarını analiz etmek amacıyla dört temel grafiksel gösterim yöntemi kullanılmıştır. Bu grafiklerin yorumlanmasında esas alınan kriterler aşağıda detaylandırılmıştır:

- **Bland-Altman Analizi (Hacimsel Tutarlılık):** Bland–Altman analizi (Bland ve Altman, 1986), iki nicel ölçüm yöntemi arasındaki uyumu değerlendirmek amacıyla kullanılan istatistiksel bir yöntemdir. Korelasyon katsayısı iki değişken arasındaki doğrusal ilişkiyi ölçmekle birlikte yöntemler arasındaki sistematik hatayı tespit etmekte yetersiz kaldığından, iki yöntem arasındaki uyumun yalnızca bu katsayıya dayanılarak değerlendirilmesi yanıltıcı sonuçlara yol açabilmektedir. Bland–Altman analizi, her bir gözlem için iki yöntem arasındaki farkların, bu iki yöntemin ortalamasına karşı grafiğe dökülmesine dayanır. Bu sayede ölçümler arasındaki sistematik sapma ve sapmanın ölçüm büyüklüğüne bağlı olarak değişip değişmediği görsel ve nicel olarak değerlendirilebilir.

Bland-Altman diyagramının yorumlanmasında amaç uyumu ölçmek değil farkların tespit edilebilmesidir. Grafiksel yorumlamada ilk adım, ortalama farkı temsil eden yatay çizginin (bias) sıfır noktasından ne kadar saptığını incelemektir; sıfırdan anlamlı sapmalar, bir yöntemin diğerine göre sabit bir aşırı veya eksik tahmin eğiliminde olduğunu gösterir.

İkinci adımda ise, farkların bu ortalama etrafındaki saçılımı, yani %95 uyum sınırları analiz edilir. Veri noktalarının sınırlar içinde homojen dağılması ve bu sınırların kabul payı içinde olması, yöntemlerin birbirinin yerine kullanılabilmesini gösterir. Buna karşın, saçılımda görülen huni şeklindeki genişleme veya belirli bir eğilim (trend), korelasyon analiziyle fark edilemeyen ve ölçüm büyüklüğüne bağlı gelişen 'orantısız hataya' işaret eder.

- **Yatay Eksen (X):** Yer-gerçek ve tahmin edilen maskelerin ortalama hacminin 10 tabanında logaritması ($\log_{10}(\text{Ortalama Hacim})$) gösterilmiştir. Logaritmik ölçek, çok küçük ve çok büyük tümörlerin aynı düzlemde analiz edilmesini sağlar.
- **Dikey Eksen (Y):** Hacimsel farkın yüzdesel oranı ($\frac{GT-Tahmin}{Ortalama} \times 100$) yer alır. Pozitif değerler tümörün olduğundan küçük (under-segmentation), negatif değerler ise olduğundan büyük (over-segmentation) tahmin edildiğini gösterir.
- **Referans Çizgileri:** Kırmızı düz çizgi sistematik hatayı (Bias), siyah kesikli çizgiler ise %95 güven aralığındaki uyum sınırlarını (Limits of Agreement - LoA, ± 1.96 Standart Sapma) temsil eder. Veri noktalarının bu sınırlar içinde kalması, yöntemin klinik olarak tutarlı olduğunu gösterir.

Kutu Grafikleri (Box-Plot) ile Hacimsel Grup Analizi: Kutu grafikleri, veri setinin dağılım özelliklerini; medyan, çeyrekler arası aralık ve uç değerler üzerinden özetleyerek betimsel istatistikleri görselleştiren etkili bir yöntemdir. Bu çalışmada, segmentasyon başarısının tümör boyutuna göre değişimini analiz etmek amacıyla veri seti, tümör hacimlerine göre dört eşit kantil grubuna (Q1: Küçük, Q2: Orta, Q3: Orta-Büyük, Q4: Büyük) ayrılmıştır. Her bir hacim grubu için hesaplanan Dice benzerlik katsayılarının dağılımı kutu grafikleri ile sunularak, önerilen algoritmanın farklı lezyon boyutlarındaki kararlılığı ve performansı istatistiksel olarak değerlendirilmiştir.

Grafiğin yorumlanmasında, kutunun ortasından geçen yatay çizgi ilgili grubun medyan başarısını, kutunun alt ve üst sınırları ise verinin orta %50'lik dilimini temsil eder. Kutunun dikey eksenindeki boyu ne kadar kısaysa, algoritmanın o hacim grubunda o kadar kararlı sonuçlar ürettiği anlaşılır. Kutuların uzantıları dışında kalan noktalar ise istatistiksel olarak aykırı kabul edilen ve algoritmanın başarısız olduğu nadir vakaları işaret eder. Bu analiz, özellikle büyük ve heterojen kitlelerde performansın düşüp düşmediğini veya varyansın artıp artmadığını tespit etmek için kritik bir göstergedir.

- Kutunun ortasındaki yatay çizgi grubun **medyan** Dice skorunu gösterir.
- Kutunun alt ve üst sınırları sırasıyla 1. (Q1) ve 3. (Q3) çeyrekleri temsil eder.
- Kutuların dikey uzunluğu (IQR), o gruptaki performans kararlılığını ifade eder; kısa kutular daha kararlı, uzun kutular ise değişken performansını işaret eder.

Dice Skoru Histogramı ve Yoğunluk Eğrileri: Histogram analizi ve Kernel Yoğunluk Tahmini, bir veri setindeki sürekli değişkenlerin frekans dağılımını ve olasılık yoğunluğunu

görselleştirmek için kullanılır. Çalışmada, 78 hastaya ait MR kesitleri üzerinde elde edilen Dice katsayılarının dağılım karakteristiğini belirlemek amacıyla bu yöntem tercih edilmiştir. Grafikteki çubuklar belirli aralıklardaki başarı frekansını gösterirken, üzerine çizilen sürekli eğri, başarının genel eğilimini ve dağılımın şeklini sola çarpık, sağa çarpık veya çok tepeli ifade eder. Ayrıca, dağılımın merkezi eğilim ölçüleri olan aritmetik ortalama ve medyan değerleri dikey referans çizgileriyle işaretlenerek, genel performansın sayısal özeti sunulur. Bu grafiğin yorumlanmasında temel amaç, algoritmanın başarısının rastgele mi yoksa belirli bir aralıkta mı yoğunlaştığını saptamaktır. Dağılımın sağ tarafa yaslanması ve medyan çizgisinin ortalamadan yüksek olması, başarısız vakaların azınlıkta olduğunu ve algoritmanın çoğu vakada yüksek doğruluk sağladığını gösteren “sola çarpık” bir yapıyı işaret eder. Eğer dağılım geniş bir alana yayılmışsa veya birden fazla tepe noktası içeriyorsa, bu durum algoritmanın farklı görüntü tiplerinde tutarsız davrandığına; dar ve yüksek bir tepe ise sonuçların kararlı ve güvenilir olduğuna delil teşkil eder.

- **Kırmızı Kesikli Çizgi:** Dağılımın aritmetik ortalamasını gösterir.
- **Yeşil Düz Çizgi:** Dağılımın medyan değerini gösterir. Dağılımın sağa yaslanması ve medyan çizgisinin ortalamadan yüksek olması, başarısız vakaların azınlıkta olduğunu ifade eder.

Maliyet-Başarım (NFEV vs. Dice) Saçılım Analizi: Saçılım grafikleri iki değişken arasındaki ilişkiyi ve korelasyonu görselleştirmek için kullanılan temel bir araçtır. Bu çalışmada, meta-sezgisel algoritmaların (PSO ve CS) hesaplama verimliliğini kıyaslamak amacıyla, yatay ekseninde Fonksiyon Değerlendirme Sayısı (NFEV) ve dikey ekseninde Dice katsayısı kullanılarak bir maliyet-başarım analizi yapılmıştır. NFEV, algoritmanın optimum eşik değerini bulmak için amaç fonksiyonunu kaç kez çağırdığını, yani işlemsel maliyeti temsil ederken; Dice skoru elde edilen sonucun doğruluğunu gösterir. Farklı algoritmalar veya profiller, grafik üzerinde farklı renk veya sembollerle kodlanarak ayrıştırılmıştır.

Grafiğin yorumlanmasında ideal senaryo, veri noktalarının grafiğin sol üst köşesinde kümelensektir. Bu durum, algoritmanın az işlem gücü harcayarak yüksek doğruluklu sonuçlar ürettiğini, yani verimli çalıştığını gösterir. Noktaların sağa doğru kayması, algoritmanın aynı başarıya ulaşmak için daha fazla işlem yaptığını; aşağı doğru kayması ise doğruluğun düştüğünü ifade eder. Bu analiz, özellikle Parçacık Sürüsü ve Guguk Kuşu algoritmalarının hangisinin “hız” ve “doğruluk” dengesini daha iyi kurduğunu ve hangi vakaların optimizasyon sürecini zorladığını belirlemek için kullanılır.

- **Yatay Eksen (X):** Fonksiyon Değerlendirme Sayısı (Number of Function Evaluations - NFEV), algoritmanın çözüme ulaşmak için harcadığı hesaplama maliyetini gösterir.
- **Dikey Eksen (Y):** Elde edilen Dice skorunu gösterir.

- Grafik üzerinde sol üst köşede (Düşük NFEV, Yüksek Dice) kümelenen noktalar, algoritmanın "yüksek verimlilikle" çalıştığını kanıtlar.

4. DENEYSEL ÇALIŞMALAR

4.1. Algoritma ve Sistem Parametreleri

Çalışmasında önerilen sistemin başarımı; bileşenlerin nihai segmentasyon üzerindeki etkilerini izole etmek amacıyla beş farklı deneysel profil ve dört farklı hacim grubu üzerinden sistematik olarak analiz edilmiştir. Deneysel sürecin adımları ve konfigürasyon detayları aşağıda maddeler halinde sunulmuştur:

- (1) **Donanım ve Yazılım:** Tüm deneyler, yüksek hesaplama yükünü karşılamak üzere **AMD Ryzen 5 5600X** işlemci, **32 GB RAM** ve **NVIDIA GeForce RTX 3060 Ti** GPU donanımına sahip bir iş istasyonunda gerçekleştirilmiştir. Yazılım tarafında Python 3.x ortamı kullanılmış; görüntü işleme ve vektörel hesaplamalar için OpenCV, NumPy ve SciPy kütüphanelerinden, paralel işlem hızlandırması için ise **CUDA** mimarisinden yararlanılmıştır.
- (2) **Veri Seti Seçimi ve Hazırlığı:** TCIA-LGG veri tabanındaki toplam 7856 görüntü taranmış; tümör varlığı uzmanlarca doğrulanmış, artefakt içermeyen ve tanısal kesinlik taşıyan **78 hasta kesiti** çalışma kümesine dahil edilmiştir. Sağlıklı beyin kesitleri ve patolojik durumu belirsiz görüntüler, istatistiksel sapmaları önlemek amacıyla analiz dışı bırakılmıştır.
- (3) **Algoritma Parametreleri ve Konfigürasyon:** Önerilen hibrit amaç fonksiyonunun optimizasyonunda, ön elemeler sonucunda en yüksek kararlılığı gösteren **Parçacık Sürüsü (PSO)** ve **Guguk Kuşu (CS)** algoritmaları kullanılmıştır. Algoritmaların parametreleri Tablo 4.1 ve 4.3 referans alınarak şu şekilde ayarlanmıştır:
 - **PSO:** Dinamik atalet ağırlığı (w) stratejisi ile başlangıçta 0.72'den 0.36'ya lineer azaltım; bilişsel (c_1) ve sosyal (c_2) katsayılar sabit 1.6.
 - **CS:** Keşif olasılığı (P_a) 0.25, Lévy uçuşu dağılım parametresi (λ) 1.5 ve adım boyu katsayısı (α) 0.01.
 - **Popülasyon:** Arama uzayının büyüklüğüne göre dinamik ölçeklendirme yapılmış; eşik sayısı (m) arttıkça popülasyon büyüklüğü artırılmıştır.

Tablo 4.1. Meta-Sezgisel algoritma parametreleri

Algoritma	Parametre	Hızlı Profili	Dengeli Profili
PSO	İterasyon Sayısı	50	80
	Atalet Ağırlığı	0.72 - 0.38	0.72 - 0.36
	Bilişsel Katsayı	1.6	1.6
	Sosyal Katsayı	1.6	1.6
CS	İterasyon Sayısı	70	90
	Keşif Olasılığı	0.25	0.25
	Adım Boyu Katsayısı	0.010	0.010
	Levy Uçuşu Dağılımı	1.5	1.5

Tablo 4.2. Eşik seviyelerine göre algoritma popülasyon büyüklükleri

Eşik Seviyesi (m)	PSO (Parçacık Sayısı)		CS (Popülasyon Büyüklüğü)	
	Hızlı	Dengeli	Hızlı	Dengeli
$m = 5$	25	30	30	35
$m = 6$	30	36	36	42
$m = 7$	35	42	42	49
$m = 8$	40	48	48	56
$m = 9$	45	54	54	63
$m = 10$	50	60	60	70
$m = 11$	55	66	66	77
$m = 12$	60	72	72	84
$m = 13$	65	78	78	91

(4) Tümör Hacmine Göre Alt Grup Analizi: Yöntemin nesne boyutuna duyarlılığını ölçmek için veri seti dört kantil grubuna ayrılmıştır:

- **Q1 (Küçük):** Başlangıç evresindeki minimal kitleler.
- **Q2 (Orta):** Orta ölçekli ve belirgin kitleler.
- **Q3 (Orta-Büyük):** Yayılım göstermeye başlayan kitleler.
- **Q4 (Büyük):** Çerçeve sınırlarını zorlayan, nekrotik ve heterojen dev kitleler.

(5) Karşılaştırmalı Optimizasyon Profilleri: Sistemin farklı modüllerinin (ön işleme, son işleme, iterasyon sayısı) etkisini ölçmek için beş farklı senaryo kurgulanmıştır:

- **Dengeli-Tam Profil:** Yüksek iterasyon (PSO: 80, CS: 90) ile maksimum doğruluk hedeflenmiş, tüm ön/son işlemler aktiftir. Referans başarı senaryosudur.

- **Hızlı-Tam Profil:** Düşük iterasyon (PSO: 50, CS: 70) ile hız ve yakınsama yeteneği test edilmiştir.
- **Hızlı-NoCLAHE:** Histogram eşitleme (CLAHE) kapatılarak, kontrast iyileştirmenin segmentasyon üzerindeki etkisi izole edilmiştir.
- **Hızlı-NoPost:** Morfolojik son işlemler (delik doldurma, küçük parça silme) devre dışı bırakılarak ham algoritma çıktısı analiz edilmiştir.
- **Hızlı-Rényi Ağırlıklı:** Hibrit fonksiyondaki ağırlıklar değiştirilerek (Rényi baskınlığı artırılarak) parametrik duyarlılık test edilmiştir.

Tablo 4.3. Hibrit amaç fonksiyonu ve genel sistem parametreleri

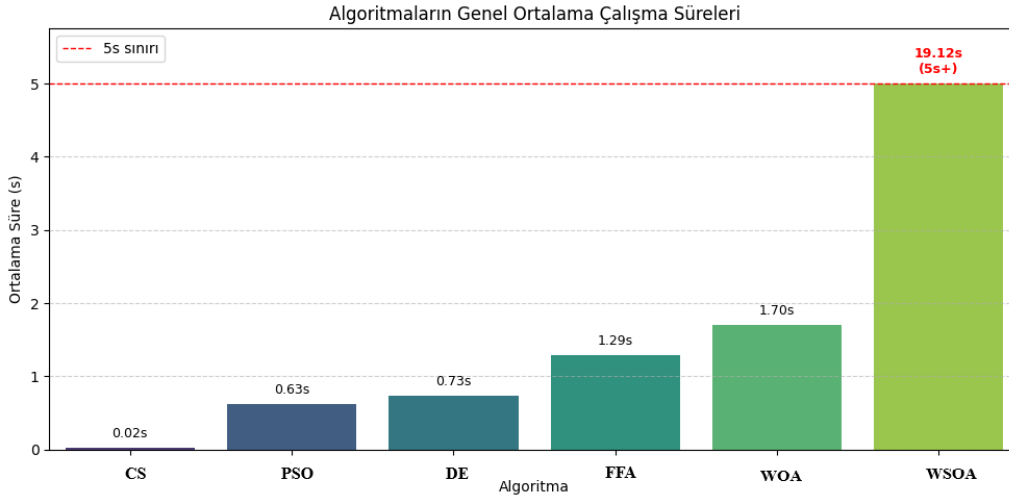
Kategori	Parametre	Değer / Tanım
Hibrit Ağırlıklar	Otsu Ağırlığı	0.20
	Kapur Ağırlığı	0.50
	Rényi Ağırlığı	0.30
Entropi Parametresi	Rényi Alfa	1.1
Arama Uzayı	Gri Seviye Aralığı	0 - 255 (8-bit)
	Minimum Eşik Boşluğu	3
Ön İşleme	Temel Seed Değeri	12345
	Beyin Maskesi Erozyon Payı	6 piksel
Cezalandırma	Yumuşak Kuantil Sınırı	0.02 - 0.98

(6) Performans Değerlendirme Metrikleri: Elde edilen sonuçların klinik geçerliliği üç farklı kategoride değerlendirilmiştir:

- **Alan Bazlı:** Dice Benzerlik Katsayısı (DSC) ve Jaccard İndeksi (IoU).
- **Mesafe/Sınır Bazlı:** Hausdorff Mesafesi (HD95), Ortalama Simetrik Yüzey Mesafesi (ASSD) ve Boundary-F1 skoru.
- **İstatistiksel:** Hacimsel tutarlılık ve sistematik hata analizi için Bland-Altman grafikleri; hesaplama maliyeti için Fonksiyon Değerlendirme Sayısı (NFEV).

4.1.1. Meta sezgisel algoritma işlem süreleri

Önerilen segmentasyon sisteminin klinik ortamlarda uygulanabilirliğini değerlendirmek amacıyla, optimizasyon algoritmalarının işlem süreleri ve hesaplama maliyetleri analiz edilmiştir. Şekil 4.1’de sunulan süre grafiğinde görüldüğü üzere, Parçacık Sürüsü Optimizasyonu ve Guguk Kuşu Arama algoritmaları arasında işlem yükü açısından belirgin bir fark bulunmaktadır. PSO



Şekil 4.1. Algoritmaların işlem süreleri karşılaştırması

algoritması, dinamik atalet ağırlığı stratejisi sayesinde arama uzayında hızlıca yakınsayarak 3000-4500 fonksiyon değerlendirme sayısı bandında çözüme ulaşmakta ve böylece genel işlem süresini önemli ölçüde minimize etmektedir. Buna karşın CS algoritması, arama uzayında gerçekleştirdiği Lévy uçuşları mekanizmasıyla yerel optimum tuzaklarından kurtulma konusunda yüksek bir başarı sergilese de, benzer bir sonuca ulaşmak için 5500-8500 NFEV aralığında çalışarak çok daha yüksek bir hesaplama maliyeti ve işlem süresi gerektirmektedir. Bu bulgular, PSO'nun düşük hesaplama maliyetiyle rekabet edebilir sonuçlar üreterek zaman kısıtının bulunduğu gerçek zamanlı tıbbi asistan sistemleri için son derece verimli bir alternatif olduğunu; CS'nin ise süre kısıtının bulunmadığı ve maksimum doğruluğun hedeflendiği senaryolarda tercih edilebilecek güçlü bir yöntem olduğunu kanıtlamaktadır.

4.2. Tümör Hacmine Göre Alt Grup Analizleri

Segmentasyon modelinin nesne boyutuna karşı duyarlılığını ölçmek amacıyla, veri seti tümör hacimlerine göre dört farklı kantil grubuna (Q1-Q4) ayrılmıştır. Bu gruplandırma kriterleri aşağıda sunulmuştur:

1. Q1 (Küçük): Veri setindeki en küçük hacimli kitleleri kapsar.
2. Q2 (Orta): Orta ölçekli kitle hacimlerini temsil eder.
3. Q3 (Orta-Büyük): Yayılımı genişlemeye başlamış kitleleri içerir.
4. Q4 (Büyük): En yüksek hacme sahip dev kitleleri tanımlar.

Değerlendirme sürecinde, alan bazlı doğruluğu saptamak için Dice katsayısı; sınır hassasiyetini milimetrik uzayda ölçmek için Ortalama Simetrik Yüzey Mesafesi (ASSD) ve 95. Persentil Hausdorff Mesafesi (HD95) metrikleri kullanılmıştır. Ek olarak, geometrik kontur bütünlüğü Boundary-F1 ölçütü ile valide edilmiştir.

Tablo 4.4. Q1-Küçük hacimli tümörlere ait Dice ve ASSD sonuçları

Optimizasyon Profili	Dice Ort.	Dice Std.	ASSD Ort.	ASSD Std.
Dengeli-Tam	0.7977	0.1452	1.9383	1.7540
Hızlı-Tam	0.7568	0.2110	2.8500	3.5443
Hızlı-NoCLAHE	0.8083	0.1083	1.6236	1.1247
Hızlı-NoPost	0.8083	0.1083	1.6236	1.1247
Hızlı-Renyi Ağırlıklı	0.8060	0.1062	1.6649	1.1472

Tablo 4.5. Q1-Küçük hacimli tümörlere ait HD95 ve Boundary F1 sonuçları

Optimizasyon Profili	HD95 Ort.	HD95 Std.	B. F1 Ort.	B. F1 Std.
Dengeli-Tam	9.2085	7.3137	0.7179	0.1556
Hızlı-Tam	10.9327	10.2278	0.6698	0.2012
Hızlı-NoCLAHE	8.3939	5.7728	0.7366	0.1420
Hızlı-NoPost	8.3939	5.7728	0.7366	0.1420
Hızlı-Renyi Ağırlıklı	8.3705	5.7115	0.7238	0.1500

Q1 grubu verileri (Tablo 4.4 ve Tablo 4.5), segmentasyon alanının dar olmasına rağmen hibrit yöntemin küçük hacimli kitlelerde yüksek kararlılıkla çalıştığını kanıtlamaktadır. Dengeli-Tam profilinin 0,7977 Dice ortalaması ve buna eşlik eden 1,93 mm'lik düşük ASSD değeri, küçük lezyonlarda dahi sınır hassasiyetinin yüksek bir başarıyla korunduğunu kanıtlamaktadır. Özellikle Hızlı-NoCLAHE ve Hızlı-NoPost senaryolarının özdeş performans sergilemesi (Dice: 0,8083, ASSD: 1,62 mm), küçük hacimli tümörlerde lezyonun sınırlı histogram dağılımı nedeniyle kontrast iyileştirme ve morfolojik son işlem adımlarının performans kazanımının belirli bir eşik değerinde doyuma ulaştığını ortaya koymaktadır. Sınır doğruluğunu ölçen HD95 değerlerinin 8,37 mm seviyelerine kadar düşmesi, modelin uç değer hatalarını minimize ederek anatomik sınır bütünlüğünü sağladığını doğrulamaktadır.

Tablo 4.6. Q2-Orta hacimli tümörlere ait Dice ve ASSD sonuçları

Optimizasyon Profili	Dice Ort.	Dice Std.	ASSD Ort.	ASSD Std.
Dengeli-Tam	0.7704	0.2224	3.1416	4.0817
Hızlı-Tam	0.7603	0.2337	4.8792	9.1937
Hızlı-NoCLAHE	0.7648	0.2114	4.6042	11.2943
Hızlı-NoPost	0.7648	0.2114	4.6042	11.2943
Hızlı-Renyi Ağırlıklı	0.6914	0.2967	8.7014	14.7795

Q2 grubu verileri (Tablo 4.6 ve Tablo 4.7), tümör hacmi arttıkça modelin performans kararlılığını koruduğunu, ancak şekil karmaşıklığına bağlı olarak standart sapma değerlerinde bir miktar artış yaşandığını göstermektedir. Dengeli-Tam profili 0.7704 Dice ortalaması ile en yüksek başarıyı sergilerken , Renyi Ağırlıklı senaryoda Dice skorunun 0.69'a gerilemesi ve ASSD hatasının 8.70 mm'ye yükselmesi; bu hacim grubunda hibrit amaç fonksiyonunu oluşturan parametre setinin doğru konfigüre edilmesinin çıktı maskesinin yapısal bütünlüğü üzerindeki belirleyici rolünü kanıtlamaktadır. Boundary-F1 skorlarında gözlemlenen değişimler ise, orta ölçekli kitlelerde sınır netliğinin ve geometrik doğruluğun optimize edilebilmesi için

Tablo 4.7. Q2-Orta hacimli tümörlere ait HD95 ve Boundary F1 sonuçları

Optimizasyon Profili	HD95 Ort.	HD95 Std.	B. F1 Ort.	B. F1 Std.
Dengeli-Tam	12.5584	7.3137	0.7179	0.1556
Hızlı-Tam	16.7047	23.6336	0.5535	0.2318
Hızlı-NoCLAHE	15.5484	27.2990	0.5755	0.5773
Hızlı-NoPost	15.5484	27.2990	0.5755	0.2209
Hızlı-Renyi Ağırlıklı	21.9920	30.6430	0.5044	0.2864

algoritmanın yakınsama süresinin önemli bir kriter olduğunu ortaya koymaktadır.

Tablo 4.8. Q3-Orta hacimli tümörlere ait Dice ve ASSD sonuçları

Optimizasyon Profili	Dice Ort.	Dice Std.	ASSD Ort.	ASSD Std.
Dengeli-Tam	0.7643	0.2153	3.9427	5.4349
Hızlı-Tam	0.7313	0.2520	4.9403	7.9568
Hızlı-NoCLAHE	0.7506	0.2051	4.5763	5.9247
Hızlı-NoPost	0.7506	0.2051	4.5763	5.9247
Hızlı-Renyi Ağırlıklı	0.7435	0.2036	4.8836	6.0131

Tablo 4.9. Q3-Orta hacimli tümörlere ait HD95 ve Boundary F1 sonuçları

Optimizasyon Profili	HD95 Ort.	HD95 Std.	B. F1 Ort.	B. F1 Std.
Dengeli-Tam	18.1033	23.1403	0.5523	0.2206
Hızlı-Tam	18.5474	19.9014	0.5204	0.2097
Hızlı-NoCLAHE	22.7392	26.5836	0.5210	0.2115
Hızlı-NoPost	22.7392	26.5836	0.5210	0.2115
Hızlı-Renyi Ağırlıklı	24.6558	28.4260	0.5220	0.2193

Q3 grubu verileri (Tablo 4.8 ve Tablo 4.9), hacim büyümesine rağmen ASSD (3.94 mm) ve Dice (0.76) skorlarının rekabetçi seviyelerde kaldığını göstermektedir. Ancak HD95 değerlerinin 18 mm seviyelerinden başlayarak 24 mm bandına kadar yükselmesi, kitle büyüdükçe sınır belirsizliklerinin ve infiltratif yayılım alanlarının segmentasyon üzerindeki zorlayıcı etkisini yansıtmaktadır. Hızlı-NoCLAHE profilinin Dice skoru açısından Dengeli-Tam profiline yakın sonuçlar vermesi (0.7506), büyük kitlelerde global histogram özelliklerinin yerel detaylardan daha baskın hale geldiğini işaret etmektedir.

Q4 grubu verileri incelendiğinde (Tablo 4.10 ve Tablo 4.11), segmentasyon performansındaki düşüşün temelinde iki ana faktör yatmaktadır. İlki, büyük hacimli gliomaların sergilediği yüksek heterojen iç yapı ve nekrotik alanların, varyans temelli (Otsu) ve enformasyon temelli (Kapur/Rényi) eşikleme kriterlerini yanıltmasıdır. İkinci ve daha teknik bir zorluk ise, dev kitelerin görüntü çerçevesinin kenarlarına taşması veya belirlenen İlgi Alanı (ROI) sınırlarını zorlamasıdır. Bu durum, algoritmanın tümör sınırlarını belirlerken ihtiyaç duyduğu 'arka plan' bilgisinin azalmasına ve dolayısıyla sınır hassasiyetinin (ASSD: 8.28 mm) düşmesine neden olmaktadır. Bu bulgular, yöntemin fiziksel uzamsal kısıtlar altında dahi klinik olarak kabul edilebilir bir baz çizgisini koruduğunu göstermektedir.

Tablo 4.10. Q4-Büyük hacimli tümörlere ait Dice ve ASSD sonuçları

Optimizasyon Profili	Dice Ort.	Dice Std.	ASSD Ort.	ASSD Std.
Dengeli-Tam	0.6868	0.2515	8.2841	19.6418
Hızlı-Tam	0.6298	0.2811	13.1149	24.6344
Hızlı-NoCLAHE	0.6833	0.2344	5.9851	16.0253
Hızlı-NoPost	0.6833	0.2344	5.9851	16.0253
Hızlı-Renyi Ağırlıklı	0.6777	0.2329	5.9246	15.7093

Tablo 4.11. Q4-Büyük hacimli tümörlere ait HD95 ve Boundary F1 sonuçları

Optimizasyon Profili	HD95 Ort.	HD95 Std.	B. F1 Ort.	B. F1 Std.
Dengeli-Tam	25.0969	29.0909	0.4700	0.1757
Hızlı-Tam	35.4469	37.1422	0.4134	0.2061
Hızlı-NoCLAHE	18.2710	25.3491	0.4593	0.1484
Hızlı-NoPost	18.2710	25.3491	0.4593	0.1484
Hızlı-Renyi Ağırlıklı	18.3509	25.0814	0.4641	0.1489

4.3. Optimizasyon Profillerinin Karşılaştırmalı Analizi

Bu çalışmada, önerilen çok seviyeli eşikleme yönteminin performans kararlılığını ve bileşenlerinin etkisini analiz etmek amacıyla beş farklı deneysel optimizasyon profili tasarlanmıştır. Temel karşılaştırma, optimizasyon derinliğinin etkisini ölçmek için *Dengeli* ve *Hızlı* profilleri arasında yapılmış; böylece iterasyon sayısının segmentasyon başarımı üzerindeki katkısı değerlendirilmiştir. Buna ek olarak, önerilen sistemin alt modüllerinin gerekliliğini doğrulamak adına, histogram eşitleme adımının (Gonzalez ve Woods, 2008) devre dışı bırakıldığı *Hızlı-NoCLAHE* senaryosu ile ön işlemenin (kontrast eşitleme) segmentasyon başarısındaki payı kontrol edilmektedir. Delik doldurma ve küçük parça temizleme gibi iyileştirmelerin kapatıldığı *Hızlı-NoPost* senaryosu ile morfolojik son işlemlerin (Soille, 2004) ham çıktı üzerindeki etkisi ölçülmüştür. Hibrit formülasyonda ağırlık katsayılarının değiştirildiği *Hızlı-Renyi Ağırlıklı* senaryosu ile hibrit amaç fonksiyonundaki entropi (Rényi, 1961) ağırlıklarının nihai doğruluk üzerindeki hassasiyeti izole edilerek incelenmiştir. Bu sistematik analizler, önerilen hibrit mimarinin optimum konfigürasyonunu bilimsel verilerle desteklemeyi amaçlamaktadır. Elde edilen genel Dice katsayıları (Taha ve Hanbury, 2015) Tablo 4.12’de sunulmuştur.

Tablo 4.12. Genel Dice katsayısı

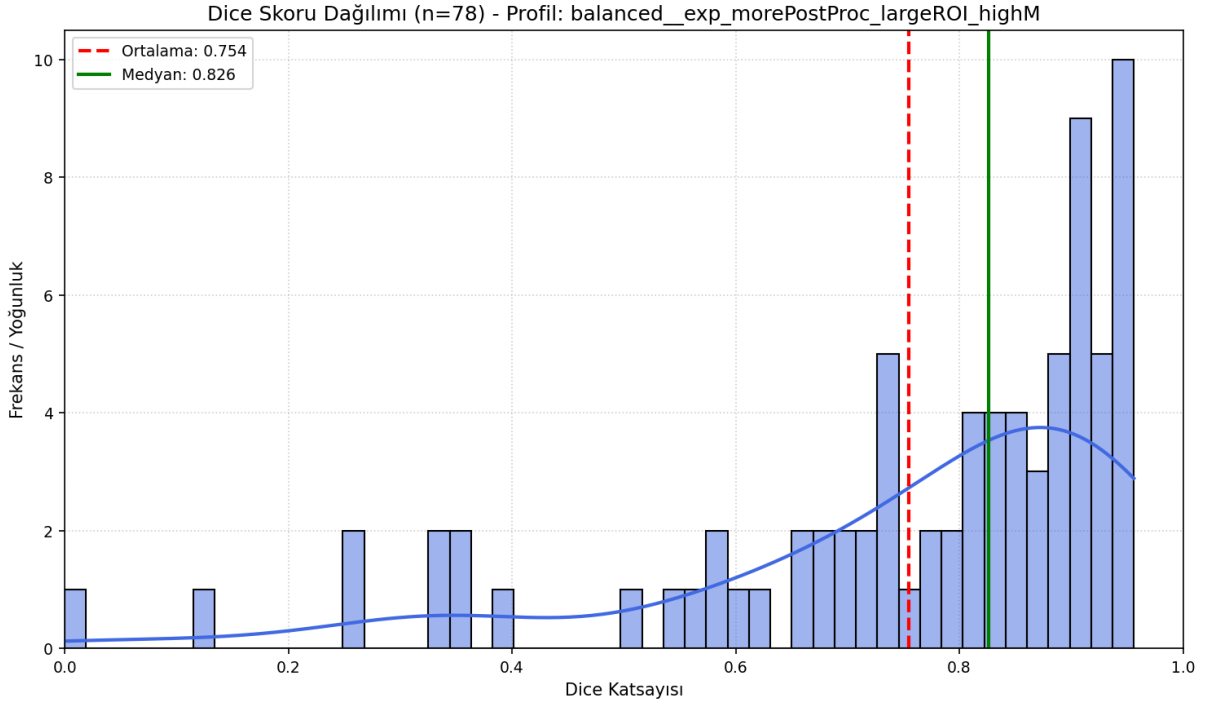
Optimizasyon Profili	Ortalama	Standart Sapma
Dengeli-Tam	0.7545	0.2121
Hızlı-Tam	0.7189	0.2470
Hızlı-NoCLAHE	0.7516	0.1970
Hızlı-NoPost	0.7516	0.1970
Hızlı-Renyi Ağırlıklı	0.7300	0.2215

4.3.1. Dengeli-Tam profili analizi


Dengeli Tam profilde kullanılarak gerçekleştirilen segmentasyon çalışmaları sonucunda, modelin klinik açıdan yüksek doğruluk ve tutarlılık sergilediği saptanmıştır. Sistemin genel başarısını temsil eden Dice Benzerlik Katsayısı medyan değeri 0,826 olarak kaydedilmiştir. Yüksek eşik sayısı ve geniş ilgi alanı (ROI) kullanımını içeren "Dengeli-Tam" profilinin, 0,7545 ortalama Dice skoru ile "Hızlı" (0,7189) ve "Renyi Ağırlıklı" (0,7300) profillerine göre daha kararlı bir performans sunduğu belirlenmiştir. Özellikle Guguk Kuşu (CS) algoritmasının dengeli profilde ulaştığı 0,83 medyan Dice başarısı, çalışmanın en yüksek performans noktası olarak kaydedilmiştir.

Tümör hacmine göre yapılan alt grup analizleri, modelin nesne boyutundan bağımsız olarak etkinliğini koruduğunu, ancak hacim ve yapısal karmaşıklık arttıkça performansın belirli bir düzeyde etkilendiğini ortaya koymuştur. En küçük hacimli tümörleri temsil eden Q1 grubunda model 1,12 mm gibi oldukça hassas bir Ortalama Simetrik Yüzey Mesafesi (ASSD) başarısı yakalamıştır. En yüksek başarı seviyelerine orta ölçekli kitlelerin yer aldığı Q2 grubunda (0,8516 medyan Dice) ulaşılırken, dev kitleleri içeren Q4 grubunda Dice skorunun 0,73 seviyelerine gerilediği ve ASSD hatasının ortalama 8,28 mm'ye yükseldiği gözlemlenmiştir.


Algoritmik verimlilik açısından yapılan değerlendirmelerde, Parçacık Sürüsü Optimizasyonu (PSO) algoritmasının 3000-4500 Fonksiyon Değerlendirme Sayısı (NFEV) ile çözüme ulaştığı, Guguk Kuşu (CS) algoritmasının ise benzer başarı için 5500-8500 NFEV harcayarak daha yüksek hesaplama maliyeti gerektirdiği saptanmıştır. Son olarak, hacimsel tutarlılığı ölçen Bland-Altman analizleri, modelin tümör hacimlerini ortalama %17,36 (Dengeli profil) ile %22,63 (Hızlı profil) oranında daha büyük ölçme eğiliminde (pozitif bias) olduğunu ancak veri noktalarının büyük çoğunluğunun %95 uyum sınırları içinde kalarak klinik bir tutarlılık sergilediğini ispatlamıştır.



Şekil 4.2. Dengeli-Tam profilinde Dice katsayısı dağılımı




Şekil 4.3. Dengeli-Tam profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği




Şekil 4.4. Dengeli-Tam profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı


Fonksiyon Değerlendirme Sayısı (NFEV) vs. Dice - Profil: balanced_exp_morePostProc_largeROI_highM



Şekil 4.5. Dengeli-Tam profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarıımı ilişkisi



TCGA_CS_4941_19960909_15 (m=8, pso, Hybrid) | Best Score (Dice): 0.8612
 Dice: 0.8612 | ASSD: 1.981 mm | HD95: 10.658 mm | BGS: 0.2073
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)



TCGA_CS_4942_19970222_14 (m=6, pso, Hybrid) | Best Score (Dice): 0.9490
 Dice: 0.9490 | ASSD: 0.339 mm | HD95: 1.414 mm | BGS: 0.0774
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)

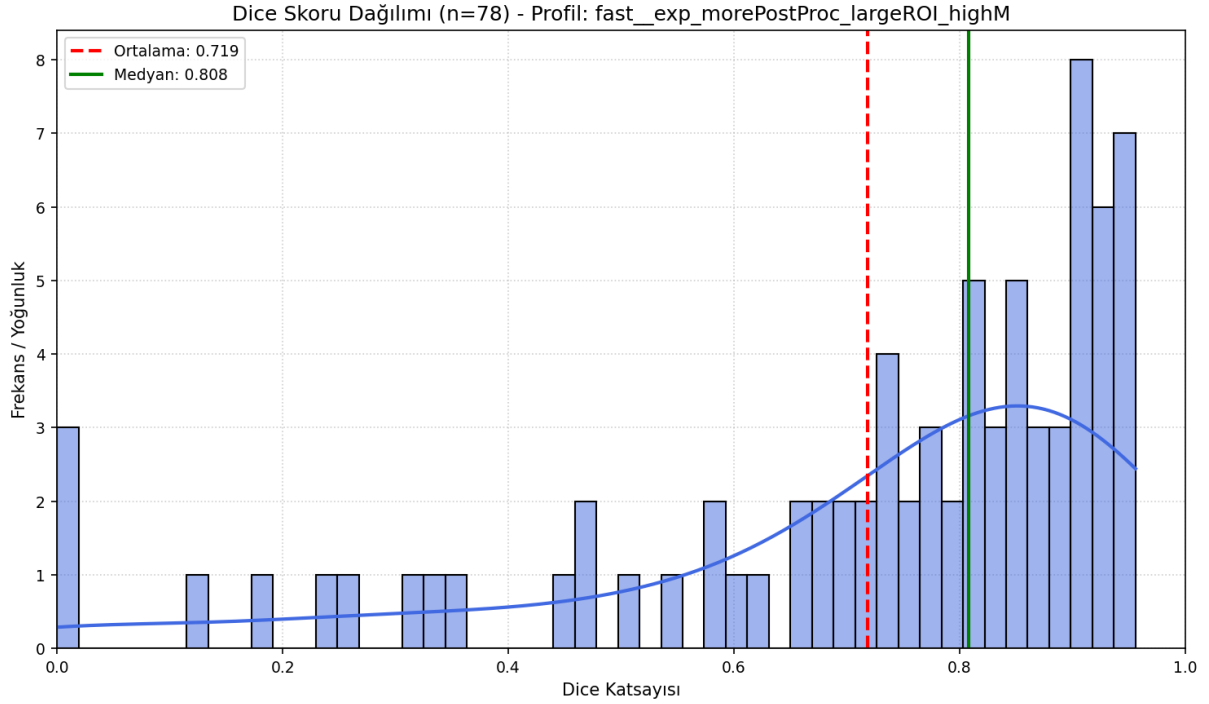
Şekil 4.6. Dengeli-Tam profilinde yüksek başarımlı örnek vakaların kesit bazlı segmentasyon sonuçları

4.3.2. Hızlı-Tam profili analizi


Hızlı-Tam optimizasyon profili kapsamında elde edilen bulgular, bu profil için genel Dice Benzerlik Katsayısı ortalaması 0,7189 ($\pm 0,2470$) olarak kaydedilirken, medyan Dice başarısının 0,808 seviyesinde olduğu saptanmıştır. Tümör hacmine dayalı alt grup analizleri incelendiğinde; en yüksek Dice ortalamasına 0,7603 ile orta hacimli (Q2) tümör grubunda ulaşılmış, bunu 0,7568 ile küçük hacimli (Q1) tümörler takip etmiştir. Hacmin arttığı Q3 ve Q4 gruplarında ise performansın sırasıyla 0,7313 ve 0,6298 seviyelerine gerilediği görülmektedir. Sınır doğruluğunu ölçen Ortalama Simetrik Yüzey Mesafesi (ASSD) değerleri, küçük hacimli tümörlerde 2,85 mm gibi hassas bir seviyede seyrederken, büyük hacimli (Q4) kitlelerde 13,11 mm'ye yükselerek kitle büyüklüğünün sınır tespitindeki zorlayıcı etkisini yansıtmıştır.

Algoritmik verimlilik değerlendirmesinde, Parçacık Sürüsü Optimizasyonu (PSO) algoritmasının Guguk Kuşu Araması (CS) algoritmasına kıyasla daha düşük Fonksiyon Değerlendirme Sayısı (NFEV) ile çözüme ulaştığı gözlemlenmiştir. Hacimsel tutarlılığın ölçüldüğü Bland-Altman analizleri sonucunda, "Hızlı-Tam" profilinin tümör hacimlerini gerçek değerden ortalama %22,63 oranında daha büyük tahmin etme eğiliminde (pozitif bias) olduğu belirlenmiştir. Bu değer, "Dengeli-Tam" profilindeki %17,36'lık sapmaya oranla daha yüksek bir hacimsel hata

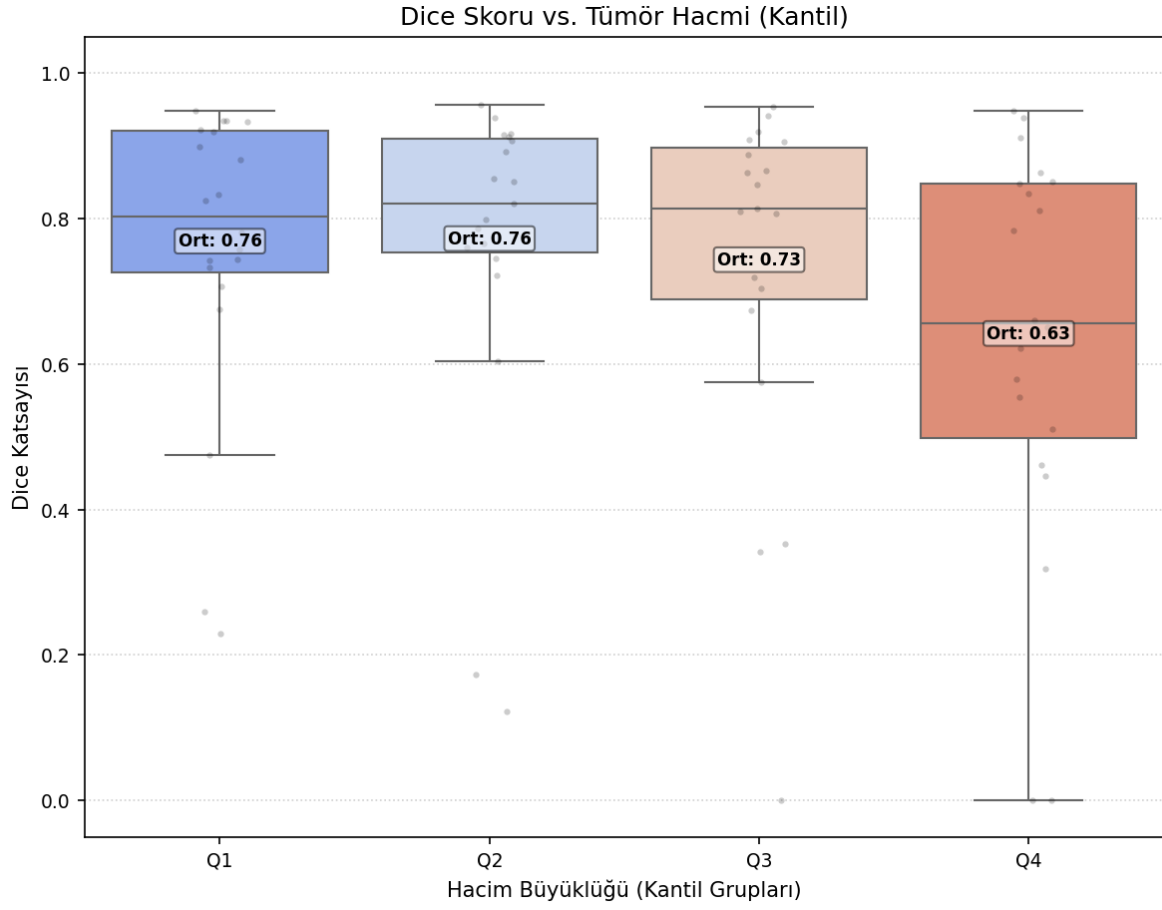
payına işaret etse de, veri noktalarının büyük çoğunluğunun %95 uyum sınırları içinde kalması yöntemin bu profil altında da istatistiksel tutarlılığını koruduğunu doğrulamaktadır. Bulgular genel olarak değerlendirildiğinde, "Hızlı-Tam" yapılandırmasının, hesaplama süresinin kritik olduğu durumlarda kabul edilebilir bir segmentasyon başarısı sunduğu saptanmıştır.



Şekil 4.7. Hızlı-Tam profilinde Dice katsayısı frekans dağılımı

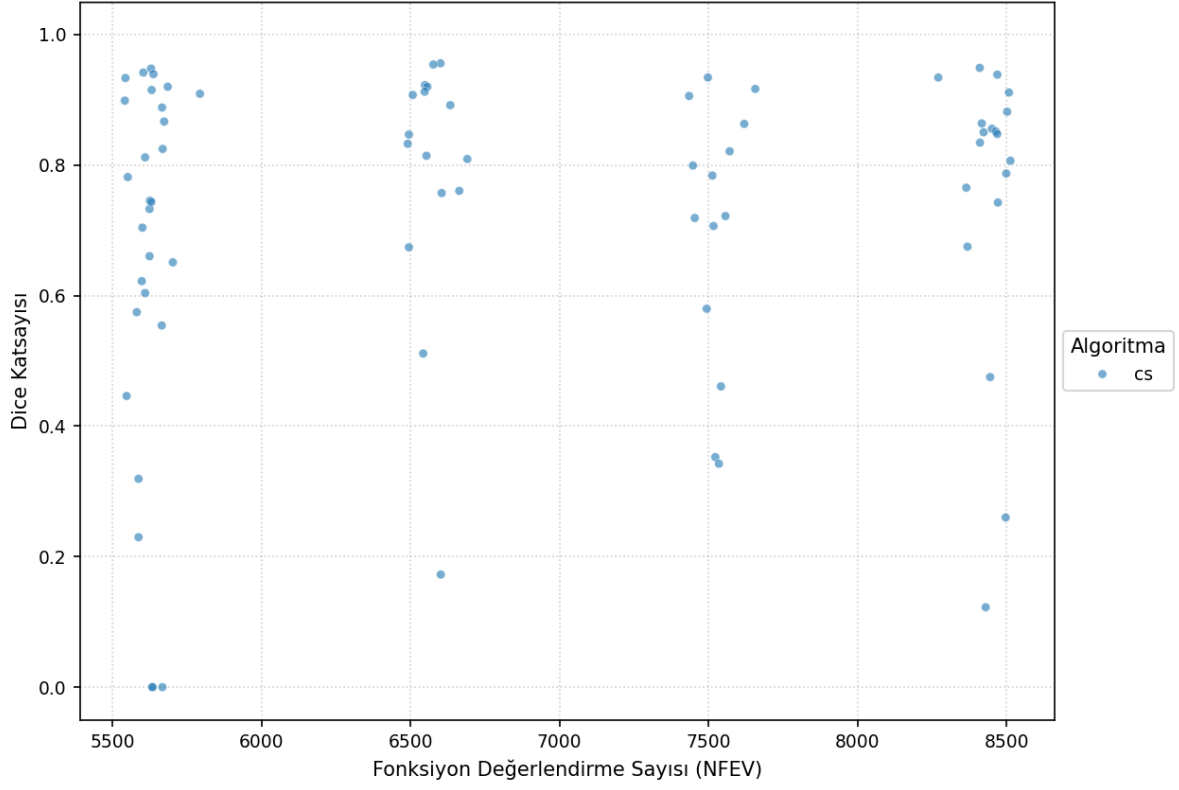


Şekil 4.8. Hızlı-Tam profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği




Şekil 4.9. Hızlı-Tam profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı


Fonksiyon Değerlendirme Sayısı (NFEV) vs. Dice - Profil: fast_exp_morePostProc_largeROI_highM



Şekil 4.10. Hızlı-Tam profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi



TCGA_CS_4941_19960909_15 (m=9, cs, Kapur) | Best Score (Dice): 0.8558
 Dice: 0.8558 | ASSD: 1.920 mm | HD95: 9.879 mm | BGS: 0.2045
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)



TCGA_CS_4942_19970222_14 (m=9, cs, Kapur) | Best Score (Dice): 0.9490
 Dice: 0.9490 | ASSD: 0.339 mm | HD95: 1.414 mm | BGS: 0.0774
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)

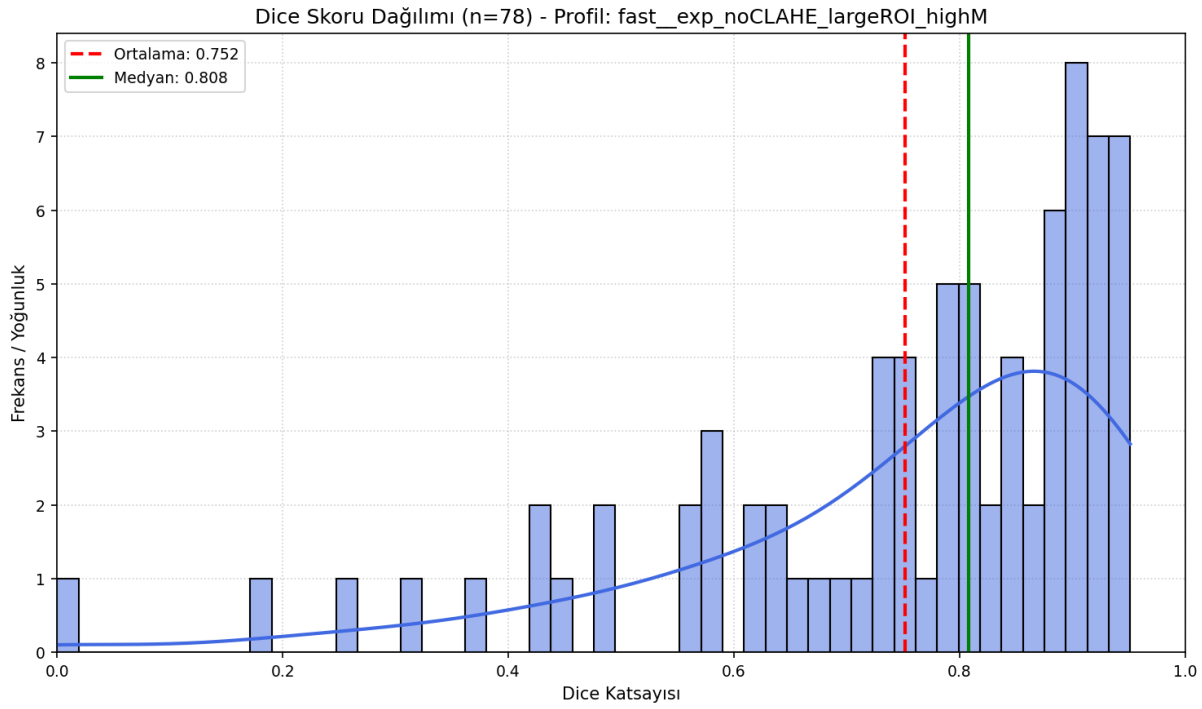
Şekil 4.11. Hızlı-Tam profilinde yüksek başarımlı örnek vakaların kesit bazlı segmentasyon sonuçları

4.3.3. Ön işleme adımının etkisi


Kontrast iyileştirme uygulanmayan (noCLAHE) profili için genel Dice katsayısı ortalaması $0.7516 (\pm 0.1970)$ olarak kaydedilirken, medyan Dice başarısının 0.808 seviyesinde olduğu saptanmıştır. İstatistiksel dağılım incelendiğinde, ortalama değer (0.752) medyan değerine (0.808) yakın seyretmesi, histogram eşitleme uygulanmasa dahi hibrit amaç fonksiyonunun stabil bir performans sergilediğini göstermektedir. Tümör hacmine dayalı alt grup analizleri, noCLAHE profilinin özellikle küçük ve büyük hacimli tümörlerde Dengeli-Tam profiline yakın sonuçlar verdiğini doğrulamaktadır. En küçük hacimli tümörleri temsil eden Q1 grubunda 0.8083 Dice ortalaması ve 1.62 mm ASSD değeri ile oldukça yüksek bir sınır hassasiyeti elde edilmiştir. Q4 grubunda ise Dice ortalaması 0.6833 seviyesinde kalarak büyük kitlelerin segmentasyonundaki genel zorluğu yansıtmıştır. Sınır doğruluğunu ölçen HD95 metriğinde, Q1 grubu için 8.39 mm gibi başarılı bir seviyeye ulaşılması, kontrast iyileştirme yapılmadığında dahi sınır netliğinin belirli bir düzeyde korunduğunu kanıtlamaktadır.

Hacimsel tutarlılığın ölçüldüğü Bland-Altman analizleri sonucunda, noCLAHE profilinin tümör hacimlerini gerçek değerden ortalama $\%15.04$ oranında daha büyük tahmin etme eğiliminde (pozitif bias) olduğu saptanmıştır. Bu sapma oranı, Hızlı-Tam profilindeki $\%22.63$ 'lük ve


Dengeli-Tam profilindeki %17.36'lık sapmalardan daha düşüktür. Algoritmik verimlilik değerlendirilmesinde ise, PSO algoritmasının CS algoritmasına kıyasla daha düşük NFEV (fonksiyon değerlendirme sayısı) ile kararlı sonuçlar ürettiği gözlemlenmiştir. Bulgular genel olarak değerlendirildiğinde, histogram eşitleme adımının (CLAHE) eksikliğinin performans üzerinde radikal bir düşüşe yol açmadığı, ancak özellikle orta ölçekli kitlelerde (Q2-Q3) doğruluğun platoya ulaştığı söylenebilir.



Şekil 4.12. Kontrast iyileştirme uygulanmayan profilinde Dice katsayısı dağılımı




Şekil 4.13. Kontrast iyileştirme uygulanmayan profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği




Şekil 4.14. Kontrast iyileştirme uygulanmayan profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı


Fonksiyon Değerlendirme Sayısı (NFEV) vs. Dice - Profil: fast_exp_noCLAHE_largeROI_highM



Şekil 4.15. Kontrast iyileştirme uygulanmayan profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımları ilişkisi



TCGA_CS_4941_19960909_15 (m=7, pso, Kapur) | Best Score (Dice): 0.8755
 Dice: 0.8755 | ASSD: 0.950 mm | HD95: 5.657 mm | BGS: 0.1900
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)



TCGA_CS_4942_19970222_14 (m=6, pso, Hybrid) | Best Score (Dice): 0.9492
 Dice: 0.9492 | ASSD: 0.338 mm | HD95: 2.000 mm | BGS: 0.0766
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)

Şekil 4.16. Kontrast iyileştirme uygulanmayan profilinde yüksek başarımlı örnek vakaların kesit bazlı segmentasyon sonuçları

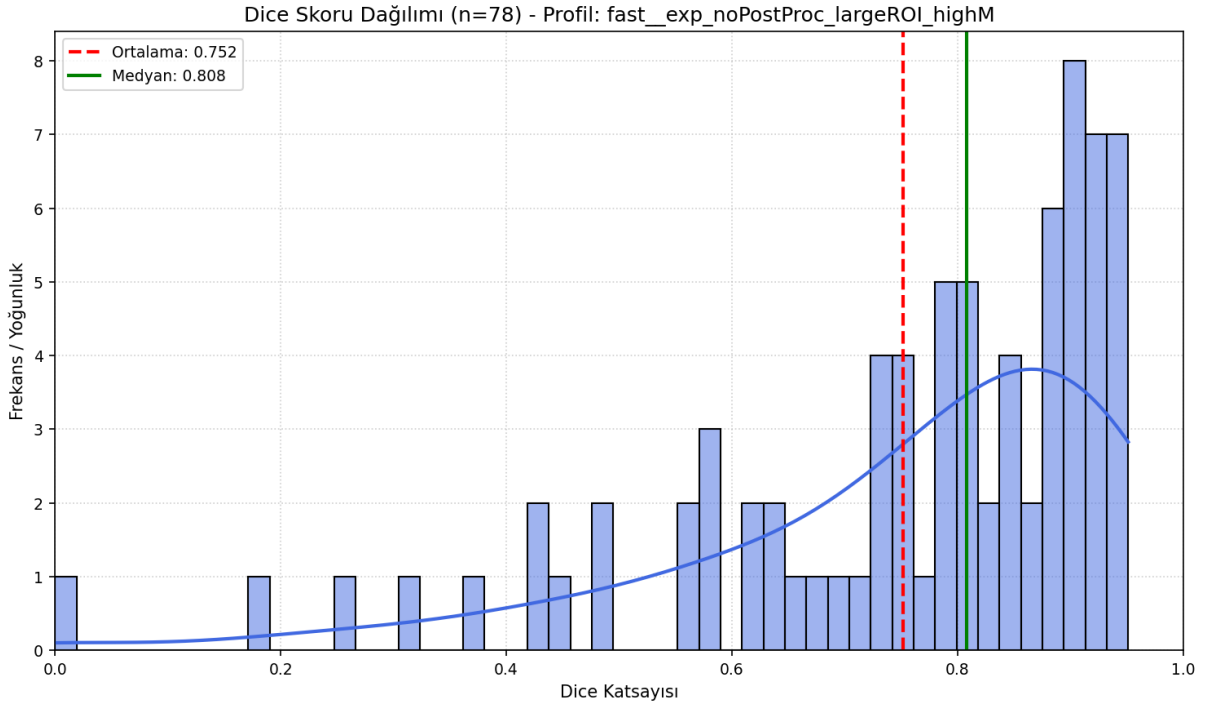
4.3.4. Son işleme adımlarının etkisi

Hızlı-NoPost Dice katsayısı ortalaması $0.7516 (\pm 0.1970)$ olarak kaydedilirken, medyan Dice başarımları 0.808 seviyesinde saptanmıştır. İstatistiksel olarak bu değerlerin "Hızlı-NoCLAHE" profili ile özdeş olması, çalışma kapsamında kullanılan bazı ön işleme ve son işleme adımlarının belirli senaryolarda benzer bir performans tabanı oluşturduğunu göstermektedir. Tümör hacmine dayalı alt grup analizleri incelendiğinde, post-proses işlemlerinin devre dışı bırakılmasının özellikle küçük ve orta hacimli tümörlerde stabil bir seyir izlediği görülmektedir. Q1 grubunda 0.8083 Dice ortalaması ve 1.62 mm ASSD değeri ile beklenenin üzerinde bir kararlılık sergilenirken, orta hacimli Q2 ve Q3 gruplarında Dice ortalamaları sırasıyla 0.7648 ve 0.7506 olarak ölçülmüş ve ham algoritma çıktısının ana kitleyi temsil etmede başarılı olduğu saptanmıştır.


En büyük hacimli tümörleri içeren Q4 grubunda Dice ortalaması 0.6833 seviyesine gerilemiş ve ASSD hatası 5.98 mm olarak kaydedilmiştir. Hacimsel tutarlılığın ölçüldüğü Bland-Altman analizleri sonucunda, bu profilin tümör hacimlerini gerçek değerden ortalama $\%15.04$ oranında daha büyük tahmin etme eğiliminde olduğu saptanmıştır. Sapma oranının standart "Hızlı-Tam" profilinden ($\%22.63$) daha düşük olması, morfolojik operasyonların, özellikle genişletme veya yayma gibi adımların, hacimsel büyümeye katkı sağladığını ve bu adımlar

uygulanmadığında tahminin gerçek hacme sayısal olarak daha yakın kaldığını göstermektedir.


Algoritmik verimlilik değerlendirmesinde, PSO algoritmasının CS algoritmasına kıyasla daha düşük Fonksiyon Değerlendirme Sayısı ile benzer başarıya ulaştığı teyit edilmiştir. Sonuç olarak, morfolojik son işlemlerin uygulanmaması medyan başarıyı radikal bir şekilde düşürmese de, özellikle düşük kontrastlı sınırlarda modelin tıbbi doğruluğunu artırmak adına bu adımların gerekliliği "Dengeli-Tam" profili ile yapılan kıyaslamalarda daha net anlaşılmaktadır.



Şekil 4.17. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde Dice katsayısı dağılımı




Şekil 4.18. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği




Şekil 4.19. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı


Fonksiyon Değerlendirme Sayısı (NFEV) vs. Dice - Profil: fast_exp_noPostProc_largeROI_highM



Şekil 4.20. Morfolojik son işlemlerin devre dışı bırakıldığı profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımları ilişkisi



TCGA_CS_4941_19960909_15 (m=7, pso, Kapur) | Best Score (Dice): 0.8755
 Dice: 0.8755 | ASSD: 0.950 mm | HD95: 5.657 mm | BGS: 0.1900
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)




TCGA_CS_4942_19970222_14 (m=6, pso, Hybrid) | Best Score (Dice): 0.9492
 Dice: 0.9492 | ASSD: 0.338 mm | HD95: 2.000 mm | BGS: 0.0766
 Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)


Şekil 4.21. Morfolojik son işlemlerin devre dışı bırakıldığı profilde yüksek başarımla sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları

4.3.5. Hibrit amaç fonksiyonunda parametrik duyarlılık rényi ağırlıklı


Hızlı-Rényi Ağırlıklı hibrit amaç fonksiyonu içerisindeki parametrik entropi ağırlığının segmentasyon doğruluğu üzerindeki etkisini nicel olarak ortaya koymaktadır. Hızlı-Rényi Ağırlıklı profil için genel Dice katsayısı ortalaması 0,7300 ($\pm 0,2215$) olarak kaydedilirken, medyan Dice başarısının 0,794 seviyesinde olduğu saptanmıştır. Tümör hacmine dayalı alt grup analizleri incelendiğinde, Q1 0,8060 Dice ortalaması ve 1,66 mm ASSD değeri ile stabil bir performans sergilediği görülmektedir. Ancak tümör hacmi arttıkça, bu profilin Dengeli-Tam profiline kıyasla daha belirgin bir performans kaybı yaşadığı saptanmıştır. Q2 grubunda Dice ortalaması 0,6914'e gerilerken, ASSD hatası 8,70 mm'ye kadar yükselmiştir. Bu durum, orta ve büyük ölçekli kitlelerde Q4 grubunda 0,6777 Dice ortalaması hibrit fonksiyon bileşenleri arasındaki dengenin bozulmasının, morfolojik bütünlük ve sınır doğruluğu üzerinde olumsuz bir etki yarattığını doğrulamaktadır. Hacimsel tutarlılığın ölçüldüğü Bland-Altman analizleri sonucunda, Rényi ağırlıklı profilin tümör hacimlerini gerçek değerden ortalama %13,35 oranında daha büyük tahmin etme eğiliminde olduğu saptanmıştır. Algoritmik verimlilik açısından PSO'nun CS'ye göre daha düşük işlem maliyetiyle benzer sonuçlar ürettiği bu profilde de gözlemlenmiştir.



Şekil 4.22. Rényi Entropi ağırlıklı hibrit fonksiyon kullanılan profilinde Dice katsayısı dağılımı

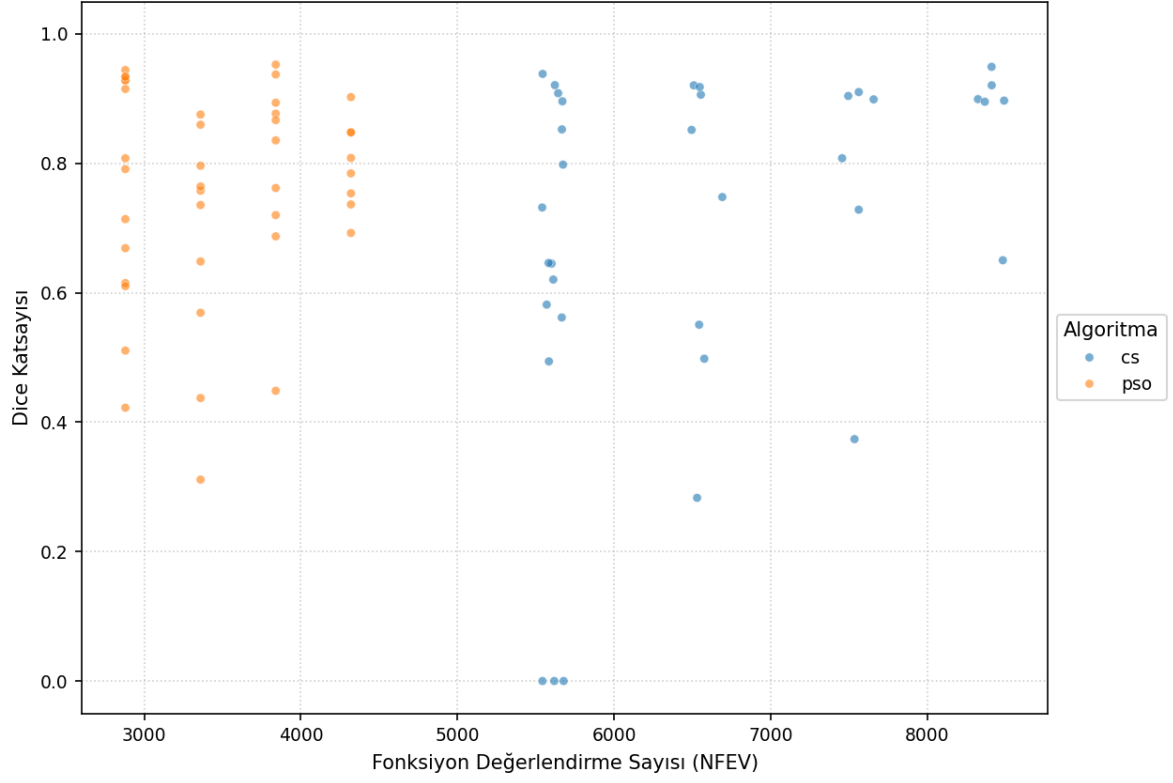


Şekil 4.23. Rényi Entropi ağırlıklı hibrit fonksiyon kullanılan profilinde hacimsel sapma oranlarını gösteren Bland-Altman grafiği




Şekil 4.24. Rényi Entropi ağırlıklı hibrit fonksiyon kullanılan profilinde tümör hacim gruplarına (Q1-Q4) göre Dice skoru dağılımı


Fonksiyon Değerlendirme Sayısı (NFEV) vs. Dice - Profil: fast_exp_renyiHeavyHyb_largeROI_highM



Şekil 4.25. Rényi Entropi ağırlıklı hibrit fonksiyon kullanılan profilinde PSO ve CS algoritmalarının fonksiyon değerlendirme sayısı (NFEV) ve Dice başarımı ilişkisi



TCGA_CS_4941_19960909_15 (m=7, pso, Kapur) | Best Score (Dice): 0.8755
Dice: 0.8755 | ASSD: 0.950 mm | HD95: 5.657 mm | BGS: 0.1900
Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)



TCGA_CS_4942_19970222_14 (m=6, pso, Hybrid) | Best Score (Dice): 0.9492
Dice: 0.9492 | ASSD: 0.338 mm | HD95: 2.000 mm | BGS: 0.0766
Original (Img) | Ground Truth (GT) | Prediction (TP:Green, FP:Yellow, FN:Red)

Şekil 4.26. Rényi Entropi ağırlıklı hibrit fonksiyon kullanılan profilinde yüksek başarımlı sergileyen örnek vakaların kesit bazlı segmentasyon sonuçları

5. SONUÇLAR VE TARTIŞMA

Yapılan analizler sonucunda, *Dengeli* optimizasyon profilinin Medyan Dice skoru açısından en yüksek başarıya ulaştığı görülmüştür. Özellikle Guguk Kuşu (CS) algoritması (Yang ve Deb, 2009), bu profilde 0.83 Medyan Dice skoruna ulaşarak, *Hızlı* profilin sağladığı 0.81 skoruna kıyasla belirgin bir iyileşme sergilemiştir. Yüksek eşik sayısı ve geniş ilgi alanı (ROI) kullanımı, tümörün karmaşık yapısının daha iyi modellenmesini sağlamış; gelişmiş son işleme adımları ise gürültüleri temizleyerek nihai maskenin tıbbi doğruluğunu artırmıştır.

Veri setindeki en küçük hacimli tümörleri temsil eden **Q1 grubu** sonuçları incelendiğinde, önerilen yöntemin 0.8105 Medyan Dice skoru ve 0.1452 seviyesindeki düşük standart sapma değerine ulaştığı görülmektedir. Literatürde, piksel sayısının azaldığı küçük lezyonlarda genellikle sınır hatasının (ASSD) artması beklenirken; önerilen yöntemin bu grupta 1.12 mm gibi oldukça hassas bir sınır doğruluğu yakalaması dikkat çekicidir. Bu başarı, uygulanan yüksek seviyeli eşikleme stratejisinin ve hibrit optimizasyonun, (Sharma vd., 2023) küçük tümör dokularını çevreleyen sağlıklı dokudan ayırt etmedeki hassasiyetini doğrulamaktadır.

Orta-küçük hacimli **Q2** ve orta-büyük hacimli **Q3** tümör grupları incelendiğinde, önerilen yöntemin performans kararlılığını koruyarak en yüksek başarımlar seviyelerine bu aralıkta ulaştığı görülmektedir. Q2 grubunda 0.8516 ile tüm veri setindeki en yüksek Medyan Dice skoru elde edilirken, hacmin arttığı Q3 grubunda da 0.8469 seviyesinde benzer bir başarı gözlemlenmiştir. Her iki grupta da ASSD (Nai vd., 2021) sırasıyla 1.81 mm ve 1.31 mm gibi düşük değerlerde kalarak, algoritmanın belirgin kitle sınırlarını tespit etmedeki yetkinliğini kanıtlamıştır. Q1 grubuna kıyasla standart sapma değerlerinin bu gruplarda 0.21 mm – 0.22 mm bandına yükselmesi, şekil bozukluklarının artmasıyla birlikte performans değişkenliğinin artmasına rağmen genel medyan başarısının sürdürüldüğünü göstermektedir.

Veri setindeki en büyük hacimli tümörleri içeren **Q4 grubunda**, segmentasyon performansında beklenen bir düşüş gözlemlenmiştir. Medyan Dice skorunun 0.7361 olarak ölçülmesi ve medyan ASSD değerinin 2.33 mm'ye, ortalama değer ise 8.28 mm'ye yükselmesi; büyük hacimli gliomaların sahip olduğu karmaşık ve belirsiz iç yapının eşikleme tabanlı yöntemler için oluşturduğu zorluğu açıkça ortaya koymaktadır. 0.25 mm ile en yüksek standart sapma değerinin bu grupta görülmesi, algoritmanın homojen tümörlerde yüksek kararlılık sergilerken, düzensiz sınırlara ve infiltratif yayılıma sahip dev kitlelerde performans değişkenliğinin arttığını doğrulamaktadır. Tüm bu zorluklara rağmen, büyük lezyonlar için elde edilen bu sonuçlar, yöntemin klinik olarak anlamlı bir segmentasyon sunabildiğini ve literatürdeki benzer eşikleme çalışmalarıyla (Kaur vd., 2018; Ma ve Hu, 2024) rekabet edebilir düzeyde olduğunu göstermektedir.

Bileşen analizi çalışmaları, önerilen yöntemin bileşenlerinin gerekliliğini net bir şekilde ortaya koymuştur. Ön işlemenin devre dışı bırakıldığı (*noCLAHE*) senaryoda performans 0.809 seviyesinde kalmış, bu da histogram eşitlemenin (Gonzalez ve Woods, 2008) kontrast iyileştir-

medeki kritik rolünü doğrulamaktadır. Morfolojik son işlemlerin (Soille, 2004) uygulanmadığı (*noPostProc*) durumda da medyan skor 0.809 olarak ölçülmüş olup, bu durum ham algoritma çıktısının iyileştirilmeye muhtaç olduğunu göstermektedir. Hibrit fonksiyonda Rényi entropisine ağırlık verilen (*renyiHeavyHyb*) senaryoda ise 0.803 medyan skor ile en düşük performans sergilenmiştir. Bu sonuç, tezde önerilen dengeli hibrit formülasyonun varyans ve entropi bilgilerini en optimum şekilde birleştirdiğini kanıtlamaktadır. Tüm bu bulgular, önerilen yöntemlerden *Dengeli-Tam* optimizasyonun yapısal bileşenleri sayesinde en kararlı ve yüksek performansı sunduğunu göstermektedir.

Literatürde PSO tabanlı yöntemlerin (Kennedy ve Eberhart, 1995), sınırları belirgin sağlıklı beyin dokularında 0.90 üzeri skorlara ulaşabildiği bilirse de, bu çalışmada ele alınan patolojik lezyonların düzensiz ve belirsiz sınır yapıları problemi önemli ölçüde zorlaştırmaktadır. Sağlıklı doku segmentasyonuna kıyasla sayısal olarak daha düşük görünen bu fark, tümörlü dokunun heterojen yapısından kaynaklanmakta olup; geliştirilen modelin ulaştığı 0.82 seviyesindeki genel Dice skoru, problemin zorluk derecesi göz önüne alındığında yöntemin yüksek etkinliğini ve klinik kullanılabilirliğini doğrulayan rekabetçi bir sonuçtur.

Bu sonucun başarısını ve literatürdeki yerini değerlendirmek amacıyla, alanındaki en güncel ve karmaşık gözetimsiz yaklaşımlardan biri olan *SynthTumour* (X. Zhang vd., 2025) ile bir karşılaştırma yapılmıştır. *SynthTumour*, hiç manuel etiket kullanmadan, iki aşamalı bir veri sentezleme stratejisi ile bir NN U-Net modelini eğiterek BraTS2021 veri setinde 0.780'lik bir Dice skoru elde etmiştir. Geliştirilen PSO-Hybrid modelimiz, gözetimli bir yaklaşımla, gözetimsiz modelle neredeyse aynı ve kısmen daha iyi bir performansa ulaşmıştır. Bu durum, özellikle büyük etiketli veri setlerinin bulunmadığı veya hızlı model geliştirmenin öncelikli olduğu durumlarda, meta-sezgisel yaklaşımların derin öğrenme tabanlı karmaşık ve veri-yoğun gözetimsiz yöntemlere (Badrinarayanan vd., 2017; Ronneberger vd., 2015) karşı ne kadar güçlü ve verimli bir alternatif olabileceğini göstermektedir.

Bu çalışmada 2 boyutlu kesitler kullanılarak hibrit bir optimizasyon yaklaşımı sunulmuştur. Gelecek çalışmalarda yöntemin 3 boyutlu MR veri setlerinde uygulanması ve Derin Öğrenme (özellikle U-Net türevleri) modelleriyle hibritlenerek başarımın artırılması planlanmaktadır.

KAYNAKÇA

- Acharya, U. K., & Kumar, S. (2021). Genetic algorithm based adaptive histogram equalization (GAAHE) technique for medical image enhancement. *Optik*, *230*, 166273. <https://doi.org/10.1016/j.ijleo.2021.166273>
- Arbeláez, P., Maire, M., Fowlkes, C., & Malik, J. (2011). Contour Detection and Hierarchical Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *33*(5), 898–916. <https://doi.org/10.1109/TPAMI.2010.161>
- Ayyarao, T. S. L. V., RamaKrishna, N. S. S., Elavarasan, R. M., Polumahanthi, N., Rambabu, M., Saini, G., Khan, B., & Alatas, B. (2022). War Strategy Optimization Algorithm: A New Effective Metaheuristic Algorithm for Global Optimization. *IEEE Access*, *10*, 25073–25105. <https://doi.org/10.1109/ACCESS.2022.3153493>
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, *39*(12), 2481–2495.
- Bhandari, A. K., Kumar, A., & Singh, G. K. (2015). Modified artificial bee colony based computationally efficient multilevel thresholding for satellite image segmentation using Kapur's, Otsu and Tsallis functions. *Expert Systems with Applications*, *42*(3), 1573–1601. <https://doi.org/10.1016/j.eswa.2014.09.049>
- Bland, J. M., & Altman, D. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *The Lancet*, *327*(8476), 307–310.
- Bovik, A. C. (Ed.). (2009). *The Essential Guide to Image Processing* (1. bs.). Academic Press (Elsevier).
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D., Pringle, M., Tarbox, L., & Prior, F. (2013). The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository. *Journal of Digital Imaging*, *26*(6), 1045–1057. <https://doi.org/10.1007/s10278-013-9622-7>
- Csurka, G., Larlus, D., & Perronnin, F. (2013). What is a good evaluation measure for semantic segmentation? *Proceedings of the British Machine Vision Conference (BMVC)*, 32.1–32.11. <https://www.bmva-archive.org.uk/2013/contents/papers/032.pdf>
- Gonzalez, R. C., & Woods, R. E. (2008). *Digital Image Processing* (3. bs.). Pearson Prentice Hall.
- Guo, H., Li, M., Liu, H., Chen, X., Cheng, Z., Li, X., Yu, H., & He, Q. (2024). Multi-threshold Image Segmentation based on an improved Salp Swarm Algorithm: Case study of breast cancer pathology images. *Computers in Biology and Medicine*, *168*, 107769. <https://doi.org/10.1016/j.combiomed.2023.107769>
- Huang, X., Shen, L., Fan, C., Zhu, J., & Chen, S. (2020). Multilevel Image Thresholding Using a Fully Informed Cuckoo Search Algorithm. *arXiv preprint arXiv:2006.09987*. <https://doi.org/10.48550/arXiv.2006.09987>
- Hussein, W. A., Sahran, S., & Abdullah, S. N. H. S. (2016). A fast scheme for multilevel thresholding based on a modified bees algorithm. *Knowledge-Based Systems*, *101*, 114–134. <https://doi.org/10.1016/j.knosys.2016.03.010>
- Jena, B., Naik, M. K., Panda, R., & Abraham, A. (2022). A novel minimum generalized cross entropy-based multilevel segmentation technique for the brain MRI/dermoscopic images. *Computers in Biology and Medicine*, *151*, 106214. <https://doi.org/10.1016/j.combiomed.2022.106214>
- Kapur, J. N., Sahoo, P. K., & Wong, A. K. C. (1985). A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram. *Computer Vision, Graphics, and Image Processing*, *29*(3), 273–285. [https://doi.org/10.1016/0734-189X\(85\)90125-2](https://doi.org/10.1016/0734-189X(85)90125-2)

- Kaur, T., Saini, B. S., & Gupta, S. (2018). A novel fully automatic multilevel thresholding technique based on optimized intuitionistic fuzzy sets and Tsallis entropy for MR brain tumor image segmentation. *Australasian Physical & Engineering Sciences in Medicine*, 41(1), 41–58. <https://doi.org/10.1007/s13246-017-0609-4>
- Kennedy, J., & Eberhart, R. (1995). Particle Swarm Optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
- Khan, W. (2013). Image Segmentation Techniques: A Survey. *Journal of Image and Graphics*, 1(4), 166–170. <https://doi.org/10.12720/joig.1.4.166-170>
- Kuijff, H. J., Biesbroek, J. M., de Bresser, J., Heinen, R., vd. (2019). Standardized Assessment of Automatic Segmentation of White Matter Hyperintensities and Results of the WMH Segmentation Challenge. *IEEE Transactions on Medical Imaging*, 38(11), 2556–2568. <https://doi.org/10.1109/TMI.2019.2905770>
- Ma, J., & Hu, J. (2024). An improved particle swarm optimization for multilevel thresholding medical image segmentation. *PLOS ONE*, 19(12), e0306283. <https://doi.org/10.1371/journal.pone.0306283>
- Mehta, R., Filos, A., Baid, U., Sako, C., McKinley, R., Rebsamen, M., Dätwyler, K., Meier, R., Radojewski, P., Murugesan, G. K., Nalawade, S., Ganesh, C., Wagner, B., Yu, F. F., vd. (2022). QU-BraTS: MICCAI BraTS 2020 Challenge on Quantifying Uncertainty in Brain Tumor Segmentation – Analysis of Ranking Scores and Benchmarking Results. *Machine Learning for Biomedical Imaging*, 1, 1–54. <https://doi.org/10.59275/j.melba.2022-354b>
- Mirjalili, S., & Lewis, A. (2016). Whale optimization algorithm. *Advances in Engineering Software*, 95, 51–67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>
- Nai, Y., Teo, B. W., Tan, N. L., vd. (2021). Comparison of metrics for the evaluation of medical segmentations using prostate MRI dataset. *Computers in Biology and Medicine*, 134, 104497. <https://doi.org/10.1016/j.combiomed.2021.104497>
- Nyúl, L. G., & Udupa, J. K. (1999). On standardizing the MR image intensity scale. *Magnetic Resonance in Medicine*, 42(6), 1072–1081. [https://doi.org/10.1002/\(SICI\)1522-2594\(199912\)42:6<1072::AID-MRM11>3.0.CO;2-M](https://doi.org/10.1002/(SICI)1522-2594(199912)42:6<1072::AID-MRM11>3.0.CO;2-M)
- Otsu, N. (1979). A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66. <https://doi.org/10.1109/TSMC.1979.4310076>
- Pedano, N., Flanders, A. E., Scarpace, L., Mikkelsen, T., Eschbacher, J. M., Hermes, B., Sisneros, V., Barnholtz-Sloan, J., & Ostrom, Q. (2016). *The Cancer Genome Atlas Low Grade Glioma Collection (TCGA-LGG), Version 3 [Dataset]*. The Cancer Imaging Archive (TCIA). <https://doi.org/10.7937/K9/TCIA.2016.L4LTD3TK>
- Rényi, A. (1961). On measures of entropy and information. *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 547–561.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* 18, 234–241.
- Sahoo, P. K., Wilkins, C., & Yeager, J. (1997). Threshold Selection Using Rényi's Entropy. *Pattern Recognition*, 30(1), 71–84. [https://doi.org/10.1016/S0031-3203\(96\)00065-9](https://doi.org/10.1016/S0031-3203(96)00065-9)
- Sharma, S. R., Alshathri, S., Singh, B., Kaur, M., Mostafa, R. R., & El-Shafai, W. (2023). Hybrid Multilevel Thresholding Image Segmentation Approach for Brain MRI. *Diagnostics*, 13(5), 925. <https://doi.org/10.3390/diagnostics13050925>

- Soille, P. (2004). *Morphological Image Analysis: Principles and Applications* (2. bs.). Springer. <https://doi.org/10.1007/978-3-662-05088-0>
- Storn, R., & Price, K. (1997). Differential Evolution—A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization*, *11*(4), 341–359. <https://doi.org/10.1023/A:1008202821328>
- Taha, A. A., & Hanbury, A. (2015). Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool. *BMC Medical Imaging*, *15*, 29. <https://doi.org/10.1186/s12880-015-0068-x>
- Tao, W., Jin, H., & Liu, L. (2007). Object segmentation using ant colony optimization algorithm and fuzzy entropy. *Pattern Recognition Letters*, *28*(7), 788–796. <https://doi.org/10.1016/j.patrec.2006.11.007>
- The Cancer Imaging Archive (TCIA). (2025). Data Usage Policies and Restrictions. <https://www.cancerimagingarchive.net/data-usage-policies-and-restrictions/>
- Uzun, Y., & Bilgin, M. (2025). Medical image enhancement using war strategy optimization algorithm. *Biomedical Signal Processing and Control*, *106*, 107740. <https://doi.org/10.1016/j.bspc.2025.107740>
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, *13*(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- Yang, X. (2009). Firefly algorithms for multimodal optimization. *Stochastic Algorithms: Foundations and Applications (SAGA 2009)*, *LNCS 5792*, 169–178. https://doi.org/10.1007/978-3-642-04944-6_14
- Yang, X., & Deb, S. (2009). Cuckoo Search via Lévy flights. *2009 World Congress on Nature & Biologically Inspired Computing (NaBIC)*, 210–214. <https://doi.org/10.1109/NABIC.2009.5393690>
- Yeghiazaryan, V., & Voiculescu, I. D. (2018). Family of boundary overlap metrics for the evaluation of medical image segmentation. *Journal of Medical Imaging*, *5*(1), 015006. <https://doi.org/10.1117/1.JMI.5.1.015006>
- Zhang, L., Zhang, L., Mou, X., & Zhang, D. (2011). FSIM: A Feature Similarity Index for Image Quality Assessment. *IEEE Transactions on Image Processing*, *20*(8), 2378–2386. <https://doi.org/10.1109/TIP.2011.2109730>
- Zhang, X., Ou, N., Liu, C., Zhuo, Z., Matthews, P. M., Liu, Y., Ye, C., & Bai, W. (2025). Unsupervised brain MRI tumour segmentation via two-stage image synthesis. *Medical Image Analysis*, *102*, 103568. <https://doi.org/https://doi.org/10.1016/j.media.2025.103568>

EKLER

EK-1: Yazılım Kaynak Kodları ve Depo Erişimi Bu tez çalışmasında kullanılan "Brain-MRI-Multilevel-Thresholding-Segmentation" pipeline yapısının ana modülleri aşağıda sunulmuştur. Yazılımın güncel sürümüne, kurulum talimatlarına ve tüm fonksiyonel kütüphanelerine aşağıdaki bağlantıdan erişilebilir:

GitHub Depo Bağlantısı: <https://github.com/necdetburak/Brain-MRI-Multilevel-Thresholding-Segmentation>