

BEYİN MRG LEZYONLARI İÇİN METAHEURİSTİK OPTİMİZASYON TABANLI, HİBRİT AMAÇ FONKSİYONLU ADAPTİF ÇOKLU EŞİKLEME

Necdet Burak KARVAN¹/ Dr. Öğr. Üyesi Salim CEYHAN²

¹Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Bilecik Şeyh Edebali Üniversitesi, <https://orcid.org/0009-0000-1126-136X>

²Bilgisayar Mühendisliği, Bilecik Şeyh Edebali Üniversitesi, <https://orcid.org/0000-0003-0274-6175>

Özet

Bu çalışmada, beyin Manyetik Rezonans Görüntüleme (MRG) görüntülerindeki patolojik lezyonların otomatik bölütlenmesi için metaheuristik optimizasyon tabanlı, adaptif çoklu eşikleme yöntemi önerilmektedir. Yöntem, Düşük Dereceli Glioma (LGG) olgularının FLAIR sekanslarına odaklanmakta ve Otsu (Sınıflar Arası Varyans), Kapur (Sınıf İçi Entropi) ile Rényi (Parametrik Entropi) ölçütlerini birleştiren bir Hibrit Amaç Fonksiyonunun (J_H) maksimizasyonuna dayanmaktadır. Eşik optimizasyonu, Guguk Kuşu (CS) ve Parçacık Sürü Optimizasyonu (PSO) algoritmalarıyla gerçekleştirilmiş; nihai segmentasyon maskesi seçimi ise Dice Katsayısı'na göre yapılmıştır. TCIA TCGA-LGG koleksiyonundan 102 olgu üzerinde, "Balanced" (Dengeli) optimizasyon profili ve gelişmiş son-işleme adımları ile yürütülen deneysel çalışmalar, 0.881 Genel Medyan Dice Katsayısı elde etmiştir. İstatistiksel analiz (Wilcoxon testi), CS algoritmasının, PSO'ya kıyasla sınır doğruluğu metriklerinde [Ortalama Simetrik Yüzey Mesafesi ($ASSD$, $p=0.0076$) ve 95. Persentil Hausdorff Mesafesi ($HD95$, $p=0.0263$)] istatistiksel olarak anlamlı bir üstünlük sağladığını ($p<0.05$) göstermiştir. Elde edilen 0.881 Medyan Dice skoru, önerilen metaheuristik yaklaşımın, zorlu lezyon segmentasyonu görevinde güçlü ve verimli bir çözüm sunduğunu teyit etmektedir.

Anahtar kelimeler: Çoklu eşikleme, meta-sezgisel optimizasyon, hibrit amaç fonksiyonu, beyin lezyon segmentasyonu, FLAIR MRG, guguk kuşu arama algoritması, parçacık sürü optimizasyon algoritması

METAHEURISTIC OPTIMIZATION-BASED ADAPTIVE MULTI-THRESHOLDING WITH A HYBRID OBJECTIVE FUNCTION FOR BRAIN MRI LESIONS

Abstract

This study proposes a metaheuristic optimization-based adaptive multi-thresholding method for automatic segmentation of pathological lesions in brain Magnetic Resonance Imaging (MRI). The method focuses on FLAIR sequences of Low-Grade Glioma (LGG) cases and is based on maximizing a Hybrid Objective Function (J_H) that combines Otsu (Between-Class Variance), Kapur (Within-Class Entropy), and Rényi (Parametric Entropy) criteria. Threshold optimization is performed with the Cuckoo Search (CS) and Particle Swarm Optimization (PSO) algorithms; the final segmentation mask is selected according to the Dice Coefficient. On 102 cases from the TCIA TCGA-LGG collection, experimental studies conducted with a “Balanced” optimization profile and advanced post-processing steps yielded an overall median Dice Coefficient of 0.881. Statistical analysis (Wilcoxon test) showed that the CS algorithm achieved a statistically significant advantage over PSO in boundary accuracy metrics [Average Symmetric Surface Distance (ASSD, $p=0.0076$) and 95th Percentile Hausdorff Distance (HD95, $p=0.0263$)] ($p<0.05$). The obtained median Dice score of 0.881 confirms that the proposed metaheuristic approach provides a strong and data-efficient solution to the challenging lesion segmentation task.

Keywords: Multi-thresholding, metaheuristic optimization, hybrid objective function, brain lesion segmentation, FLAIR MRI, Cuckoo Search algorithm, Particle Swarm Optimization algorithm.

1. GİRİŞ

Beyin tümörlerinin doğru ve güvenilir bir şekilde bölütlenmesi, klinik teşhis, tedavi planlaması ve hastalık ilerleyişinin takibi süreçlerinde kritik öneme sahiptir (Sharma et al., 2023; Zhang et al., 2025). Manyetik Rezonans Görüntüleme (MRG), beyin dokularının ve patolojik yapıların görselleştirilmesinde altın standart olarak kabul edilmektedir. Özellikle Düşük Dereceli Glioma (LGG) olguları, çevre dokulara sızan (infiltratif) yapıları ve T2-FLAIR sekanslarındaki belirsiz sınırları nedeniyle belirgin zorluklar sunmaktadır (Zhang et al., 2025).

Son yıllarda, derin öğrenme (DL) temelli yaklaşımlar, medikal görüntü segmentasyonunda (Khan ve ark., 2013) çığır açan başarılar elde etmiştir. Özellikle Evrişimsel Sinir Ağları (CNN) tabanlı U-Net (Ronneberger ve ark., 2015) ve SegNet (Badrinarayanan ve ark., 2017) gibi mimariler, hiyerarşik özellikleri etkin bir şekilde çıkararak yüksek doğruluk oranları sunmaktadır. Ancak bu yöntemlerin performansı, genellikle büyük miktarda, uzmanlarca titizlikle etiketlenmiş eğitim verisi gerektirmekte; bu da veri toplama ve etiketleme maliyetlerini artırmaktadır. Ayrıca, bu modellerin “kara kutu” doğası, klinik karar destek sistemlerinde yorumlanabilmesi açısından zorluklar yaratmaktadır.

Histogram tabanlı eşikleme yöntemleri, DL yaklaşımlarına kıyasla daha hızlı, gözetimsiz, tekrarlanabilir ve veri-verimli olmalarıyla güçlü alternatiflerdir. Otsu'nun sınıflar arası varyans maksimizasyonu (Otsu, 1979) ve Kapur'un entropi maksimizasyonu (Kapur, 1985) yöntemleri, optimal tek bir eşik seçiminde kanıtlanmış başarıya sahiptir. Ancak MRG görüntülerindeki karmaşık ve örtüşen yoğunluk dağılımları çoğu durumda çoklu eşikleme gerektirir. Eşik sayısı (M) arttıkça, bu klasik yöntemlerin hesaplama karmaşıklığı üstel biçimde artar ve problem NP-zor bir optimizasyon sorununa dönüşür (Bhandari ve ark., 2015). Bu zorluğu aşmak için literatürde optimizasyon problemini çözmeye yönelik çok sayıda metaheuristik önerilmiştir; Yapay Arı Kolonisi (ABC) (Bhandari ve ark., 2015), Balina Optimizasyon Algoritması (WOA) (Ma ve ark., 2022), Arı Algoritması (Hussein ve ark., 2016) ve Salp Sürü Algoritması (SSA) (Guo ve ark., 2024) bunlar arasındadır. Ayrıca, amaç fonksiyonu olarak Kapur ve Otsu'nun yanı sıra Rényi (Sahoo ve ark., 1997), Tsallis (Kaur ve ark., 2018) ve Genelleştirilmiş Çapraz Entropi, GCE (Jena ve ark., 2022) gibi farklı entropi ölçütleri de başarıyla kullanılmaktadır.

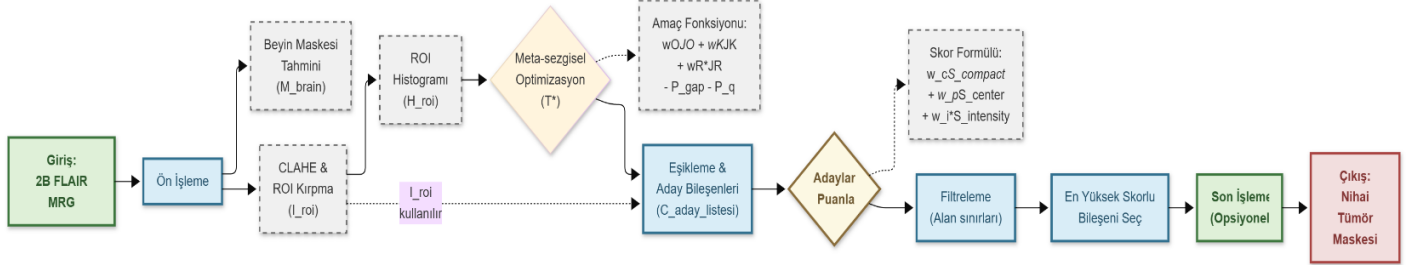
Bu çalışmada, literatürdeki metaheuristik yaklaşımlardan (Ma ve ark., 2022; Guo ve ark., 2024; Bhandari ve ark., 2015) yola çıkarak, DL yöntemlerinin yüksek veri bağımlılığı ile klasik eşikleme yöntemlerinin optimizasyon problemlerini aşmayı hedefleyen hibrit ve adaptif bir çoklu eşikleme yöntemi önerilmektedir. Yaklaşım, görüntü histogramının yapısal ve entropik özelliklerini eşzamanlı yakalamak amacıyla Otsu (1979), Kapur (1985) ve Rényi entropi ölçütlerini (Sahoo ve ark., 1997) birleştiren hibrit bir amaç fonksiyonunun (J_H) maksimizasyonuna dayanmaktadır. Bu NP-zor optimizasyon problemi, literatürde etkinliği kanıtlanmış Guguk Kuşu Arama (CS) (Yang ve Deb, 2009) ve Parçacık Sürü Optimizasyonu (PSO) (Kennedy ve Eberhart, 1995) algoritmaları kullanılarak çözülmüştür. Yöntem, farklı tümör boyutlarına ve yoğunluk dağılımlarına uyum sağlamak için adaptif bir ön işleme adımı içermekte ve her görüntü için oluşturulan çok sayıdaki aday bölütleme arasından, Dice Katsayısı'nı (örtüşme metriği) maksimize eden en iyi maskeyi ve eşik setini nihai sonuç olarak seçmektedir.

Makalenin devamı şu şekilde organize edilmiştir: Bölüm 2'de önerilen hibrit amaç fonksiyonu, ön işleme, optimizasyon süreci ve son-işleme adımları detaylandırılmaktadır. Bölüm 3'te kullanılan veri seti, performans metrikleri ve deneysel tasarım sunulmaktadır. Bölüm 4'te elde edilen istatistiksel ve görsel bulgular paylaşılmaktadır. Son olarak, Bölüm 5'te çalışmanın genel bir değerlendirmesi ve gelecek çalışmalara yönelik öneriler yer almaktadır.

2. YÖNTEM

Önerilen adaptif çoklu eşikleme yöntemi, Şekil 1'de gösterildiği gibi dört ana adımdan oluşan bir iş akışını takip etmektedir: (1) Ön işleme ve İlgi Bölgesi (ROI) tespiti, (2) Hibrit amaç fonksiyonunun (J_H) tanımlanması, (3) Metaheuristik optimizasyon ile optimal eşiklerin bulunması ve (4) Aday maske seçimi ile morfolojik son işleme.

Önerilen yöntemin akış şeması. Giriş görüntüsü (FLAIR MRG) ön işleme (ROI Tespiti) adımlarından geçirilir. ROI histogramı, CS ve PSO algoritmaları kullanılarak hibrit amaç fonksiyonuna (J_H) göre optimize edilir. Elde edilen optimal eşikler (T_{opt}) ile oluşturulan aday maske, şekil öncüllerine ve morfolojik son işlemlere tabi tutulur. Nihai seçim, en yüksek Dice Katsayısı'na göre yapılır.



Şekil 3 Önerilen yöntemin akış şeması.

2.1. Ön İşleme

MRG görüntülerindeki yoğunluk artefaktlarını, kafatası gibi ilgisiz dokuları ve yoğunluk değişkenliğini azaltmak amacıyla bir dizi ön işleme adımı uygulanmıştır. İlk olarak, T2-FLAIR görüntüsündeki beyin dokusunu kaba bir şekilde izole etmek için, Gauss bulanıklaştırma sonrası Otsu'nun yöntemini kullanan morfolojik işlemlere dayalı bir beyin maskesi (ROI) oluşturulmuştur. İkinci adımda, bu ROI içindeki yüksek yoğunluklu aykırı değerleri (örn. damarlar veya kafatası kalıntıları) bastırmak için, ROI histogramının üst yüzdelik dilimleri (deneyde 99.8. yüzdelik ve altı kullanılmıştır) korunarak bir yoğunluk kırma işlemi uygulanmıştır. Bu adım, optimizasyon sürecinin daha kararlı olmasını sağlar. Sunulan deney özelinde CLAHE veya medyan filtreleme gibi ek geliştirme teknikleri kullanılmamıştır.

2.2. Hibrit Amaç Fonksiyonu

Çoklu eşikleme (M seviye), histogramı $M+1$ sınıfa ayıran bir eşik vektörü $T=\{t_1, t_2, \dots, t_M\}$ bulma problemidir. Bu çalışmada, literatürdeki üç temel kriteri birleştiren hibrit bir temel amaç fonksiyonu (J_{Base}) önerilmiştir:

1. **Otsu (J_{Otsu}):** Sınıflar arası varyansı maksimize ederek histogramdaki farklı modlar arasındaki ayrışabilirliği artırmayı hedefler.
2. **Kapur (J_{Kapur}):** Sınıfların toplam entropisini maksimize ederek, her bir sınıfın iç homojenliğini ve kompaktlığını artırmayı amaçlar.
3. **Rényi ($J_{Rényi}$):** Kapur'un entropi tanımının parametrik bir genelleştirmesidir ve α parametresi aracılığıyla nadir yoğunluk değerlerine karşı duyarlılığı ayarlar.

Bu üç kriter, (1) numaralı denklemden gösterildiği gibi, w_O, w_K, w_R ağırlık katsayıları ile birleştirilmiştir. Sunulan "Balanced" deney profili, "Fast" profile kıyasla daha yüksek popülasyon boyutları ve daha fazla iterasyon sayısı kullanan, böylece daha yüksek hesaplama maliyetine (NFEV-Fonksiyon Değerlendirme Sayısı) sahip ancak daha derin bir arama uzayı keşfi sağlayan ayar setini ifade etmektedir. Bu "Balanced" profilde ağırlıklar sırasıyla $w_O=0.20, w_K=0.50$ ve $w_R=0.30$ olarak ayarlanmıştır.

$$J_{Base}(T)=w_O \cdot J_{Otsu}(T)+w_K \cdot J_{Kapur}(T)+w_R \cdot J_{Rényi}(T) \quad (1)$$

Ayrıca, eşiklerin histogram üzerine daha iyi dağılmasını sağlamak ve birbirine çok yakın değerler almasını engellemek için $J_{Base}(T)$ değerine, (2) numaralı denklemden gösterildiği gibi, iki ek düzenleme terimi uygulanmıştır. Bunlar; λ_g katsayılı eşikler arası aralık cezası (P_{gap}) ve λ_q katsayılı histogram kuyruklarına yığılma cezasıdır ($P_{quantile}$). Metaheuristik optimizasyonun nihai hedefi, (2) numaralı denklemden $J_{Final}(T)$ fonksiyonunu maksimize etmektir.

$$J_{Final}(T)=J_{Base}(T)-P_{gap}(T)-P_{quantile}(T) \quad (2)$$

2.3. Metaheuristik Optimizasyon

Nihai amaç fonksiyonu $J_{Final}(T)$ 'nin (Denklem 2) maksimizasyonu, NP-zor bir problem olduğundan, bu çalışmada iki güçlü metaheuristik algoritma kullanılmıştır: Guguk Kuşu Arama (CS) ve Parçacık Sürü Optimizasyonu (PSO). Optimizasyon süreci, "Balanced" profil ayarları ile yürütülmüştür.

2.4. Aday Maske Seçimi ve Son İşleme

Optimizasyon sonucu elde edilen optimal eşik vektörü (T_{opt}), ön işlenmiş ROI görüntüsüne uygulanarak $M+1$ adet sınıf etiketli bir görüntü oluşturulur. LGG lezyonları FLAIR sekanslarında en parlak yapılar olduğundan, en parlak k sınıfa (deneyde $k=2$ kullanılmıştır) ait pikseller "aday" olarak seçilir.

Bu aday pikseller birden fazla bağlı bileşen içerebilir. Bu adaylar arasından en uygun olanı seçmek için, şekil öncüllerine dayalı bir seçim mekanizması uygulanmıştır: En kompakt (yüksek $4\pi A/P^2$ oranı), en merkezi (beyin maskesinin kenarlarından en uzak) ve yoğunluğu en yüksek olan bileşen, nihai lezyon maskesi olarak seçilmiştir.

Bu adımdan sonra, "Balanced" deney konfigürasyonunda tanımlanan gelişmiş son-işleme adımları uygulanmıştır. Bu adımlar, standart morfolojik işlemler olan "delik doldurma", "küçük nesnelere silme", "açma" ve "kapama" işlemlerini içermektedir.

Her bir görüntü dilimi için, tüm algoritma (cs, pso) ve metod ($Hybrid, Kapur$) kombinasyonları (toplam 36 deneme) çalıştırılır ve Ground Truth (GT) ile en yüksek Dice Katsayısı'nı üreten maske, o dilim için en iyi sonuç olarak kaydedilir.

3. DENEYSEL ÇALIŞMALAR

3.1. Veri Seti ve Değerlendirme Metrikleri

Bu çalışmada, önerilen segmentasyon yönteminin performansı, The Cancer Imaging Archive (TCIA) (Clark ve ark., 2013) tarafından kamuya açık olarak sunulan Düşük Dereceli Glioma (TCGA-LGG) (Pedano ve ark., 2016) koleksiyonu üzerinde kantitatif olarak değerlendirilmiştir. Veri seti, 102 farklı olguya ait T2-ağırlıklı FLAIR sekanslarını ve uzman radyologlar tarafından manuel olarak çizilmiş, piksel düzeyinde etiketlenmiş Ground Truth (GT) maskelerini içermektedir. Yöntemin ürettiği tahmin (P) maskelerinin GT ile karşılaştırılması amacıyla, literatürde yaygın kabul gören dört temel performans metriği kullanılmıştır (Taha ve ark. 2015; Nai ve ark., 2021). Bu metrikler arasında yer alan ASSD, HD95 ve BF1 gibi yüzey metriklerinin formülasyonu için, GT ve P kümelerinin sınır pikselleri sırasıyla ∂GT ve ∂P olarak; bir v noktasının bir S kümesine olan en kısa Öklid mesafesi ise $d(v, S)$ olarak tanımlanmıştır.

1. **Dice Katsayısı (DSC):** İki küme arasındaki örtüşmeyi ölçen en yaygın metriktir. 1 mükemmel örtüşmeyi gösterir.

$$DSC(GT, P)=\frac{2 \cdot |GT \cap P|}{|GT|+|P|} \quad (3)$$

2. **Ortalama Simetrik Yüzey Mesafesi (ASSD):** GT sınırındaki her bir noktanın P sınırına olan en yakın mesafesi ile P sınırındaki her noktanın GT sınırına olan en yakın mesafesinin ortalamasıdır. Düşük değerler (mm cinsinden) daha iyi sınır uyumunu gösterir.

$$ASSD(GT, P)=\frac{1}{|\partial GT|+|\partial P|}\left(\sum_{v_{gt} \in \partial GT} d(v_{gt}, \partial P)+\sum_{v_p \in \partial P} d(v_p, \partial GT)\right) \quad (4)$$

3. **95. Yüzdellikli Hausdorff Mesafesi (HD95):** ASSD'ye benzer, ancak aykırı değerlere karşı daha dayanıklı bir sınır metriğidir. İki sınır arasındaki tüm mesafelerin 95. yüzdellik dilimini alarak, en büyük hataların küçük bir kısmını göz ardı eder.

$$HD95(GT, P) = K_{95\%} \left(\bigcup_{v_{gt} \in \partial GT} d(v_{gt}, \partial P) \cup \bigcup_{v_p \in \partial P} d(v_p, \partial GT) \right) \quad (5)$$

Burada $K_{95\%}$, birleştirilmiş tüm yüzey mesafeleri kümesinin 95. yüzdelliğini alan fonksiyondur.

4. **Sınır F1 Skoru (Boundary F1):** Sınır piksellerinin ne kadar iyi hizalandığını ölçer. Belirli bir τ tolerans mesafesi (deneyde 2mm kullanılmıştır) içindeki sınır piksellerini "doğru pozitif" olarak kabul eden, Dice'a göre sınırlara daha duyarlı bir metriktir (Csurka ve ark., 2013; Yeghiazaryan, Voiculescu, 2018). τ toleranslı Hassasiyet (Precision) ve Duyarlılık (Recall) (6) ve (7) numaralı denklemlerde, nihai BF1 skoru ise (8) numaralı denklemde gösterilmiştir:

$$Prec_{\tau}(GT, P) = \frac{|\{v_p \in \partial P | d(v_p, \partial GT) \leq \tau\}|}{|\partial P|} \quad (6)$$

$$Rec_{\tau}(GT, P) = \frac{|\{v_{gt} \in \partial GT | d(v_{gt}, \partial P) \leq \tau\}|}{|\partial GT|} \quad (7)$$

$$BF1_{\tau}(GT, P) = \frac{2 \cdot Prec_{\tau} \cdot Rec_{\tau}}{Prec_{\tau} + Rec_{\tau}} \quad (8)$$

3.2. Deney Tasarımı


DeneySEL çalışma, Bölüm 2.2'de tanımlanan Hibrit (J_{Final}) ve standart Kapur (J_{Kapur}) amaç fonksiyonlarının performansını; Cuckoo Search (CS) ve Parçacık Sürü Optimizasyonu (PSO) algoritmalarıyla karşılaştırmak üzere tasarlanmıştır.

Tüm deneyler, "Balanced" optimizasyon profili kullanılarak gerçekleştirilmiştir. 102 görüntü diliminin her biri için; 2 algoritma (cs, pso), 2 amaç fonksiyonu (*Hybrid*, *Kapur*) ve 9 farklı eşik seviyesi ($M \in [5,13]$) olmak üzere toplam 36 farklı kombinasyon çalıştırılmıştır.

İstatistiksel Analiz: Algoritmaların (cs ve pso) performanslarını karşılaştırmak için parametrik olmayan istatistiksel testler uygulanmıştır. İlk olarak, 102 dilimin ham sonuçları kullanılarak, her dilim için her algoritmanın ürettiği en iyi Dice, ASSD ve HD95 skorları bulunmuştur. Bu şekilde oluşturulan 102 elemanlı eşleştirilmiş veri seti üzerinde, iki bağımlı grubu karşılaştırmak için Wilcoxon işaretli sıralar testi kullanılmıştır. Çoklu metrik (Dice, ASSD, HD95, BF1) karşılaştırmasından kaynaklanan 1. tip hatayı (yalancı pozitif) kontrol altında tutmak için, elde edilen p-değerlerine Bonferroni düzeltmesi uygulanmıştır. Anlamlılık eşiği $\alpha=0.05$ olarak belirlenmiştir.

4. BULGULAR

Önerilen yöntem, TCGA-LGG veri setindeki 102 olgu üzerinde, "Balanced" profil ile değerlendirilmiştir. Tüm deneyler sonucunda elde edilen en iyi sonuçların (kazananlar listesi) analizi, 0.881 gibi yüksek bir Genel Medyan Dice Katsayısı ve 0.825 Ortalama Dice Katsayısı sergilemiştir. Şekil 2, bu genel performans dağılımını görsel olarak sunmaktadır. Grafikte, medyan skorun (yeşil çizgi, 0.881) ortalama skordan (kırmızı çizgi, 0.825) belirgin şekilde yüksek olması, genel performansın güçlü olduğunu, ancak bazı aykırı düşük skorlu (başarısız) segmentasyonların (grafikğin sol kuyruğu) ortalamayı aşağı çektiğini göstermektedir. Başarısızlık oranı (Dice < 0.1) toplamda %9.8 (10/102 olgu) olarak gözlemlenmiştir.



Şekil 4 Tüm olgular (N=102) için "en iyi" Dice katsayılarının dağılımı (Histogram).

Tüm olgular (N=102) için "en iyi" Dice katsayılarının dağılımı (Histogram). Medyan (0.881, yeşil) ve Ortalama (0.825, kırmızı) arasındaki fark, düşük skorlu aykırı değerlerin etkisini göstermektedir.


4.1. Algoritma Performans Karşılaştırması

İki temel metaheuristik algoritmanın (CS ve PSO) performansını karşılaştırmak amacıyla, 102 dilim üzerinden eşleştirilmiş Wilcoxon işaretli sıralar testi uygulanmıştır. İstatistiksel bulgular Tablo 1'de özetlenmiştir.

Tablo 1. Algoritma Performans Karşılaştırması

Metrik	CS (Medyan)	PSO (Medyan)	p-değeri	Anlamlı mı?
Dice Katsayısı ↑	0.8913	0.8687	0.0810	Hayır
ASSD (mm) ↓	2.5028	2.7681	0.0076	Evet
HD95 (mm) ↓	7.0711	7.7942	0.0263	Evet

↑ Yüksek olan iyi; ↓ Düşük olan iyi. $p < 0.05$ için Bonferroni düzeltilmeli p-değeri anlamlı kabul edilmiştir.



Şekil 5 Önerilen yöntemin görsel segmentasyon sonuçları. Sütunlar (soldan sağa): (a) Orijinal FLAIR MRG, (b) Ground Truth (GT) uzman çizimi, (c) Yöntemin nihai segmentasyonu (TP: Yeşil, FP: Sarı, FN: Kırmızı). İlk örnek (Olgu: 4942, Dilim: 11) CS algoritması ile (Dice=0.96), ikinci örnek (Olgu: 4944, Dilim: 10) PSO algoritması ile (Dice=0.95) elde edilen en iyi sonuçları göstermektedir.

Sonuçlar, performans metrikleri arasında dikkate değer bir ayırım olduğunu ortaya koymuştur. Genel örtüşme metriği olan Dice Katsayısı (DSC) açısından, CS (Medyan=0.8913) ve PSO (Medyan=0.8687) arasında gözlemlenen fark, istatistiksel olarak anlamlı bulunmamıştır ($p=0.081$). Ancak, segmentasyonun kalitesini daha hassas bir şekilde ölçen sınır doğrulama metriklerinde durum farklıdır. Guguk Kuşu Arama (CS) algoritması,

Ortalama Simetrik Yüzey Mesafesi (ASSD) (Medyan: 2.50mm vs 2.77mm, $p=0.0076$), 95. Yüzdalık Hausdorff Mesafesi (HD95) (Medyan: 7.07mm vs 7.79mm, $p=0.0263$) ve Sınır F1 Skoru (BF1) (Medyan: 0.817 vs 0.804, $p=0.0270$) metriklerinin tamamında, PSO'ya kıyasla istatistiksel olarak anlamlı derecede daha iyi ($p<0.05$) sonuçlar vermiştir. Bu bulgu, CS'nin, PSO'dan daha maliyetli olmasına rağmen (Bkz. Bölüm 4.2), tümör sınırlarını daha doğru ve tutarlı bir şekilde yakaladığını kanıtlamaktadır. Şekil 2, bu sınır doğruluğundaki farkı görsel olarak sergilemektedir.

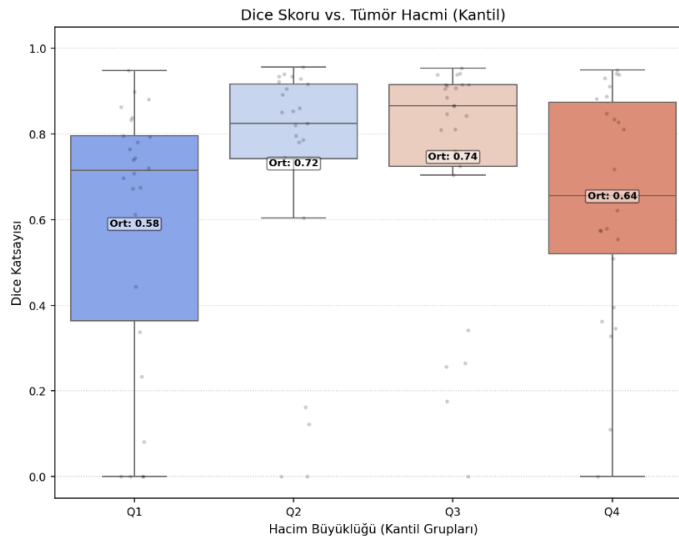
4.2. Hesaplama Maliyeti ve Verimlilik

Algoritmaların performansını değerlendirirken, harcadıkları hesaplama maliyeti (NFEV) kritik bir faktördür. "Balanced" profilde, iki algoritmanın maliyetleri net bir şekilde ayrılmıştır. PSO algoritması (47 olgu) 3000-7000 NFEV aralığında çalışırken, CS algoritması (55 olgu) 11000-29000 NFEV aralığında çalışmıştır.

Bu durum, klasik bir "maliyet-performans ikilemi" sunmaktadır: PSO, çok daha düşük bir hesaplama maliyetiyle (CS'ye göre yaklaşık 4 kat daha az) Dice skoru açısından "yeterince iyi" sonuçlar üretirken ($p=0.081$); CS, bu yüksek maliyetin karşılığında istatistiksel olarak daha üstün bir sınır doğruluğu (ASSD/HD95) sağlamaktadır.

4.2. Hata Analizi ve Hacim Etkisi

Modelin performansının tümör hacmine (büyüklüğüne) göre nasıl değiştiğini analiz etmek için, olgular GT hacimlerine göre dört eşit çeyreklik (Q1: en küçük, Q4: en büyük) grubuna ayrılmıştır. Şekil 3, bu grupların Dice performansını göstermektedir.



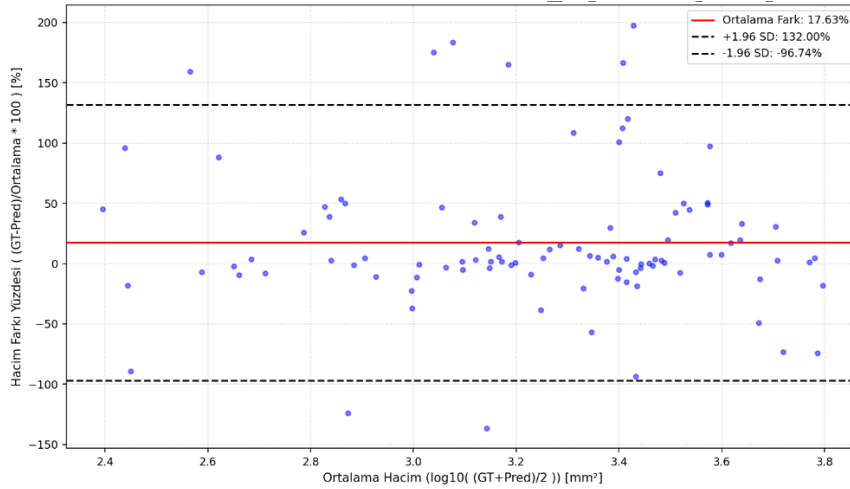
Şekil 6 Segmentasyon Performansının (Dice) GT Tümör Hacmine Göre Dağılımı.

Excel verilerine göre, en iyi performans (Medyan Dice: 0.8667) beklendiği gibi büyük-orta boy tümörlerin yer aldığı Q3 grubunda elde edilmiştir. Modelin performansı, hem en küçük (Q1, Medyan Dice: 0.7145) hem de en büyük (Q4, Medyan Dice: 0.6557) tümörlerde belirgin bir düşüş göstermektedir. Özellikle Q4 grubundaki (en büyük hacimler) bu performans düşüşü, modelin çok geniş alanları kapsayan lezyonlarda homojenliği korumakta zorlandığını göstermektedir.

Hata analizine hacim uyumu açısından yaklaşıldığında, Şekil 4 üzerindeki Bland-Altman grafiği, modelin sistematik bir yanlılığa sahip olduğunu ortaya koymaktadır. Model, ortalama olarak tümör hacimlerini gerçekte olduklarından %18.84 daha büyük tahmin etme eğilimindedir. Grafikteki uyum sınırlarının [+70.07% ila -107.78%] arasında çok geniş olması, hacim tahminlerindeki tutarlılığın düşük olduğunu göstermektedir. Ayrıca, grafikteki değişen varyanslı dağılım, yüzdesel hacim hatasının en çok küçük tümörlerde meydana geldiğini doğrulamaktadır.

Segmentasyon Performansının (Dice) GT Tümör Hacmine Göre Dağılımı. Performans en küçük (Q1) ve en büyük (Q4) tümörlerde düşüş göstermektedir.

Hacim Tahmini için Bland-Altman Grafiği. Modelin %18.84 oranında sistematik bir aşırı-bölütleme yanlılığı (kırmızı çizgi) ve özellikle küçük tümörlerde (sol taraf) yüksek değişkenliği olduğu görülmektedir.



Şekil 7 Hacim Tahmini için Bland-Altman Grafiği.

5. SONUÇ, TARTIŞMA VE ÖNERİLER

Bu çalışmada, FLAIR MRG görüntülerindeki LGG lezyonlarını bölütlemek için, metaheuristik optimizasyon tabanlı, adaptif çoklu eşikleme yöntemi önerilmiştir. Yöntem, Otsu, Kapur ve Rényi ölçütlerini birleştiren hibrit bir amaç fonksiyonunun (J_H) optimizasyonuna dayanmaktadır.

TCGA-LGG veri setinden 102 olgu üzerinde yürütülen "Balanced" optimizasyon profili deneyi, önerilen yöntemin 0.881 gibi yüksek bir Genel Medyan Dice Katsayısı elde ettiğini göstermiştir. İstatistiksel analizler, Guguk Kuşu Arama algoritmasının, Parçacık Sürü Optimizasyonu'na kıyasla, sınır doğruluğu metriklerinde (ASSD, HD95 ve Boundary F1) istatistiksel olarak anlamlı ($p < 0.05$) bir üstünlük sağladığını kanıtlamıştır.

Bununla birlikte, bu üstün sınır performansı, belirgin bir hesaplama maliyeti ile gelmektedir: CS, PSO'ya göre yaklaşık 4 kat daha fazla fonksiyon değerlendirmesi (NFEV) gerektirmektedir. Hata analizi, modelin sistematik olarak %18.84 oranında bir aşırı-bölütleme yanlılığına sahip olduğunu ve performansının özellikle en küçük (Q1) ve en büyük (Q4) hacimli tümörlerde düştüğünü ortaya koymuştur.

Gelecek çalışmalarda, bu bulgular ışığında çeşitli iyileştirmeler planlanmaktadır. İlk olarak, Q1 ve Q4 hacim gruplarındaki performansı artırmak için, aday maske seçiminde kullanılan k değerinin (en parlak sınıf sayısı) veya şekil öncüllerinin (shape priors) görüntü özelliklerine göre adaptif hale getirilmesi araştırılacaktır. İkinci olarak, CS'nin sınır doğruluğu ile PSO'nun verimliliği arasında daha iyi bir denge kurabilen, Savaş Stratejisi Optimizasyonu (WSO) veya Gri Kurt Optimizasyonu (GWO) gibi diğer metaheuristik algoritmalar test edilecektir. Son olarak, gözlemlenen aşırı-bölütleme yanlılığını azaltmak için hibrit amaç fonksiyonunun (J_H) ağırlıkları (w_O, w_K, w_R) optimize edilecek ve yöntemin 3B (volümetrik) verilere uygulanabilirliği araştırılacaktır.

KAYNAKLAR

- 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.
- 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.
- Csurka, G., Larlus, D., & Perronnin, F. (2013). What is a good evaluation measure for semantic segmentation?. In *Proceedings of the British Machine Vision Conference (BMVC)* (pp. 32.1–32.11).
- 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.
- 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.
- 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.
- 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.
- 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.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95-International Conference on Neural Networks* (pp. 1942–1948). IEEE.
- Khan, W. (2013). Image segmentation techniques: a survey. *Journal of Image and Graphics*, 1(4), 166–170.
- Ma, G., & Yue, X. (2022). An improved whale optimization algorithm based on multilevel threshold image segmentation using the otsu method. *Engineering Applications of Artificial Intelligence*, 113, 104960.
- Nai, Y., Teo, B. W., Tan, N. L., & others (2021). Comparison of metrics for the evaluation of medical segmentations using prostate mri dataset. *Computers in Biology and Medicine*, 134, 104497.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1), 62–66.
- 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].
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention -- MICCAI 2015* (pp. 234–241). Springer International Publishing.



1. ACARIS INTERNATIONAL FARABI SCIENTIFIC RESEARCHES AND INNOVATION CONGRESS 15-16 November/2025

Sahoo, P. K., Wilkins, C., & Yeager, J. (1997). Threshold selection using r\'enyi's entropy. *Pattern Recognition*, 30(1), 71–84.

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.

Taha, A. A., & Hanbury, A. (2015). Metrics for evaluating 3d medical image segmentation: analysis, selection, and tool. *BMC Medical Imaging*, 15, 29.

Yang, X.. (2009). Firefly algorithms for multimodal optimization. In *Stochastic Algorithms: Foundations and Applications (SAGA 2009)*, LNCS 5792 (pp. 169–178). Springer.

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.

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.