



Multilevel thresholding with metaheuristic methods

Yağmur Ölmez^{1*}, Abdulkadir Sengür², Gonca Ozmen Koca¹

¹Mekatronik Engineering Department, Faculty of Technology, Fırat University, 23000, Elazığ, Turkey

²Electrical and Electronics Engineering Department, Faculty of Technology, Fırat University, 23000, Elazığ, Turkey

Highlights:

- A two-dimensional histogram based on non-local means filter
- A new multilevel thresholding method based on Renyi's Entropy and PSO algorithm
- Improved results compared to existing methods.

Keywords:

- Metaheuristic Methods
- Image Segmentation
- Multilevel Thresholding
- Particle Swarm Optimization

Graphical/Tabular Abstract

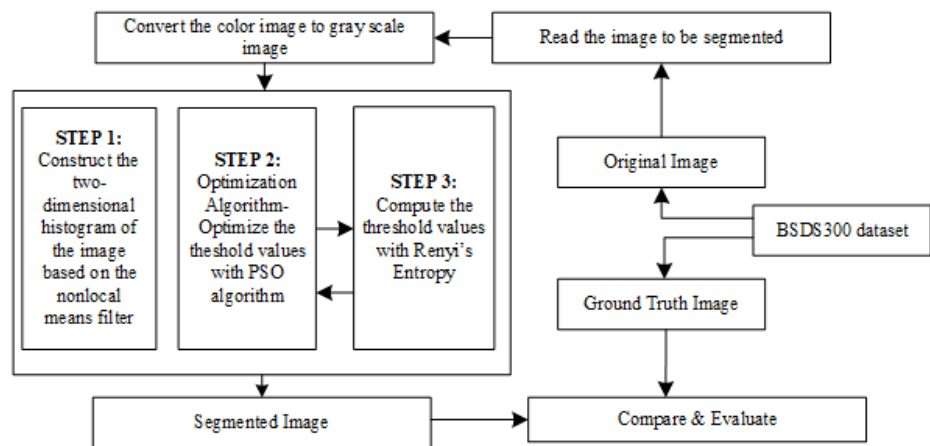


Figure A. Flowchart of the proposed method for multilevel thresholding

Article Info:

Research Article
Received: 27.04.2020
Accepted: 11.07.2020

DOI:

10.17341/gazimmfd.727811

Correspondence:

Author: Yağmur Ölmez
e-mail: yolmez@firat.edu.tr
phone: +90 424 237 0000 / 7606

Purpose:

The aim of this study is to achieve a more precise segmentation process in a shorter time by improving multi-level thresholding performance.

Theory and Methods:

2DYOH-PSO multi-level thresholding method has been presented to increase the segmentation performance of images. In the proposed method, two-dimensional histogram method based non-local means filter was used for segmentation of gray level images. Renyi's entropy as a cost function has been redefined for multi-level thresholding in the two-dimensional histogram, and the PSO algorithm has been adapted to the problem in order to find the most appropriate threshold values by reducing the calculation time. Experimental studies were carried out using the BSDS300 data set. Thresholding at different levels were applied to the images in the data set.

Results& Conclusion:

With the proposed method, the segmentation performance of the images in the BSDS300 data set were evaluated using 12 different quality measurement indices. The proposed method has been compared with the Gravity Search Algorithm (GSA) [26], Artificial Bee Algorithm (ABC) [27], Differential Evolution (DE) [28], chaotic Kbest Gravity Search Algorithm (cKGSA) [29], exponential Kbest Gravity Search Algorithm (eKGSA) [24] methods, which were quite successful in terms of 12 quality measurement indices, and more effective results were obtained with experimental studies by using this algorithm.



Meta sezgisel yöntemlerle çok seviyeli görüntü eşikleme

Yağmur Ölmez^{1*}, Abdulkadir Sengür², Gonca Ozmen Koca¹

¹Fırat Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, 23000 Elazığ, Türkiye

²Fırat Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 23000 Elazığ, Türkiye

Ö N E Ç I K A N L A R

- Yerel olmayan ortalama filtre tabanlı iki boyutlu histogram yöntemi
- PSO algoritması ve Renyi'nin entropisine dayalı çok seviyeli eşikleme yöntemi
- Mevcut yöntemlere kıyasla geliştirilmiş sonuçlar

Makale Bilgileri

Araştırma Makalesi

Geliş: 27.04.2020

Kabul: 11.07.2020

DOI:

10.17341/gazimmfd.727811

Anahtar Kelimeler:

Meta sezgisel yöntemler,
görüntü bölütleme,
çok seviyeli eşikleme,
parçacık sürü optimizasyonu

ÖZET

Bu çalışmada, hesaplama zamanını azaltmak ve çok seviyeli eşikleme performansını geliştirmek için PSO yönteminin hızlı yakınsama oranı dikkate alınarak iki boyutlu yerel olmayan histograma dayalı çok seviyeli bir eşikleme yöntemi (2DYOH-PSO) önerilmiştir. Önerilen 2DYOH-PSO yöntemi iki boyutlu Renyi'nin entropisine dayalı eşikleme yöntemi kullanılarak gerçekleştirilmiştir. Deneysel çalışmalar, Berkeley-Benchmark veri setindeki 300 görüntü için farklı seviyeli eşik değerleri dikkate alınarak yapılmıştır. Var olan 5 farklı eşik belirleme yöntemi (Diferansiyel Gelişim, Yapay Arı Algoritması, Yer Çekimi Arma Algoritması, K_{best} Yer Çekimi Arma Algoritması, Kaotik K_{best} Yer Çekimi Arma Algoritması) ile karşılaştırılarak, önerilen 2DYOH-PSO yönteminin performansı değerlendirilmiştir. 2DYOH-PSO yönteminin başarımı 12 farklı performans değerlendirme endeksi kullanılarak belirlenmiştir. 2DYOH-PSO ile 3 seviyeli eşikleme işlemi gerçekleştirildiği durumda, mevcut 5 farklı yöntem ile 12 performans değerlendirme endeksi bakımından yapılan bölütleme işlemlerinin başarımları BDE'de %2,63 oranında, PRI'de %0,83 oranında SSIM'de %15,5 oranında, RMSE'de %13,2 oranında, PSNR'de %8,63, CC'de %35 oranında, AD'de %13,9 oranında, MD'de %14,75 oranında, NAE %10 oranında iyileşme sağlanmıştır. 2DYOH-PSO ile 5 seviyeli eşikleme işlemi gerçekleştirildiği durumda ise Berkeley-Benchmark veri setindeki görüntülerin bölütlenmesinde ki başarımın BDE'de %1, VOI'de %1,4, SSIM'de %1,3, FSIM'de %0,66, RMSE'de %0,46, PSNR'de %0,46, CC'de %21,69, AD'de %0,84 oranında iyileştiği deneysel sonuçlar ile gösterilmiştir.

Multilevel thresholding with metaheuristic methods

H I G H L I G H T S

- A two-dimensional histogram based on non-local means filter
- A new multilevel thresholding method based on Renyi's Entropy and PSO algorithm
- Improved results compared to existing methods

Article Info

Research Article

Received: 27.04.2020

Accepted: 11.07.2020

DOI:

10.17341/gazimmfd.727811

Keywords:

Metaheuristic methods,
image segmentation,
multilevel thresholding,
particle swarm optimization

ABSTRACT

In this study, a multi-level thresholding method (2DYOH-PSO) based on 2D non-local means histogram is proposed, taking into account the fast convergence rate of the PSO method to reduce the computation time and improve the multi-level thresholding performance. The proposed 2DYOH-PSO method has been realized by using the two-dimensional Renyi's entropy-based thresholding method. Experimental studies are conducted for 300 images in the Berkeley-Benchmark dataset, taking into account different level threshold values. The performance of the proposed 2DYOH-PSO method is evaluated by comparing the existing 5 different threshold determination methods (Differential Evolution, Artificial Bee Algorithm, Gravity Search Algorithm, K_{best} Gravity Search Algorithm, and Chaotic K_{best} Gravity Search Algorithm). The performance of the 2DYOH-PSO method is determined using 12 different performance evaluation indices. In the case of 3-level thresholding with 2DYOH-PSO in terms of 12 performance evaluation indexes with 5 different methods, the performance of the segmentation processes shows improvements such that 2.63% in BDE, 0.83% in PRI, 15.5% in SSIM, 13.2% in RMSE, 8.63% in PSNR, 35% in CC, 13.9% in AD, 14.75% in MD, 10.04% in NAE, respectively. In the case of 5-level thresholding with 2DYOH-PSO, the performance of the segmentation processes shows 1% improvement in BDI, 0.85% in FSIM, 15.35% in RMSE, 8.88% in PSNR, 0.85% in CC and 12.8% in AD with the experimental studies.

*Sorumlu Yazar/Corresponding Author: yolmez@firat.edu.tr, ksengur@gmail.com, gonca.ozmen@gmail.com /

Tel: +90 424 237 0000 / 7606

1. GİRİŞ (INTRODUCTION)

Görüntü bölütleme, dijital bir görüntünün aynı özellikteki piksellerini parçalar halinde bir araya toplayarak çoklu bölümlere ayırma işlemidir. Oluşturulan her bir bölüm bölüt olarak adlandırılır ve her bölüt farklı özellik taşır. Bölütlemenin amacı, görüntüleri daha anlamlı ve analiz edilmesi kolay hale getirmek için basitleştirmek ve değiştirmektir.

Sinyallerin sınıflandırılması, kenar bulma problemleri, hasarlı doku tespiti, orman yangınlarının tespiti gibi çok çeşitli alanlarda ihtiyaç duyulan bölütleme işlemi görüntü analizinin ilk ve en önemli aşamalarından biridir. Prostat sınırının bulunması [1], lökosit hücrelerinin preparat görüntüsünden tespiti ve sınıflandırılması [2], EMG sinyallerinin sınıflandırılması [3] gibi farklı araştırma alanlarında gerçekleştirilen uygulamalarda bölütleme işleminin önemli rol oynadığı görülmüştür. Yine yapılan farklı bir uygulamada ekme gözeneklerinin morfojik yapısı incelenerek ekme kalitesinin analiz edilmesinde görüntü bölütleme yöntemine ihtiyaç duyulmuştur [4].

Görüntü bölütleme için geliştirilmiş olan pek çok yöntem mevcuttur. Demirhan vd. çeşitli özelliklerdeki görüntülerin bölütlenmesi için gri seviye eş oluşum matrisi ve öz-örgütlemeli harita ağları kullanarak bu yöntemlerin başarımlarını araştırmışlardır [5]. 2018 yılında yapılan çalışmada orman yangınlarının tespiti için süper piksel görüntü bölütleme yöntemi yardımıyla uzamsal komşuluk bilgilerini de kullanarak yangın bölgesinin tespiti sağlanmıştır [6]. Bir kornea bozukluğu hastalığı olan keratokonus hastalığının teşhisinde ve tedavi sonrası sürecin izlenmesi amacıyla kornea görüntülerinin bölütlenmesinde eşikleme ve Havza (Watershed) bölütleme yöntemleri kullanılmıştır [7].

Görüntü bölütleme için tasarlanan yöntemler ve bu yöntemlerin başarımları, görüntüden görüntüye ve uygulamaya dayalı olarak değişiklik arz eder. Bölgeler arasındaki benzerliğin tanımlanması ve uygulanması için geliştirilen yaklaşımlar; histogram tabanlı, kümeleme tabanlı, bölge büyütme, ayırma-birleştirme ve morfolojik yaklaşımlar olarak sınıflandırılır.

Eşikleme (thresholding) metodu, en basit ve en yaygın kullanılan bölütleme yöntemidir. 2004 yılında, Sezgin vd. eşiklemeyi, histogram şekil tabanlı yöntemler, kümeleme temelli yöntemler, entropi temelli yöntemler, nesne özniteliği temelli yöntemler, mekânsal yöntemler ve yerel yöntemler olarak altı gruba ayırmışlardır [8]. Geçtiğimiz yıllarda, bu yöntemler en uygun eşik değerlerini bulmak amacıyla iki seviyeli ve çok seviyeli bölütleme için yaygın olarak uygulanmıştır. İki seviyeli eşikleme yaklaşımlarında, görüntüler nesne ve arka plan olarak iki bölüme ayrılır. Görüntü daha büyük ayrıntıya sahipse, görüntülere çok seviyeli eşikleme uygulanır. Literatürde en sık kullanılan eşikleme amaç fonksiyonları Kapur'un entropi yaklaşımı ve

Otsu'nun sınıflar arası varyans tekniği olmuştur. Yıllar boyunca, çeşitli uygulamalar için birçok eşikleme tekniği önerilmiştir. Bunlar arasında, en etkili teknikler entropi tabanlı yaklaşımlardır. Kapur ve diğerleri tarafından önerilen entropi yöntemi, bölütlenen sınıflar arasındaki benzerliği ölçmek için entropinin maksimize edilmesi ile en uygun eşik değerleri bulmak için kullanılır. Otsu'nun yönteminde [9], en uygun eşik değerleri gri seviyelerin sınıflar arası varyansını maksimize ederek bulunmaktadır. Çok seviyeli eşik problemlerinde de Kapur ve Otsu'nun yöntemleri kolayca uygulanabilmektedir [10]. Ancak hesaplama sürelerinin çok fazla artması nedeniyle en uygun eşikleri belirlemede tek başına bu yöntemler yetersiz kalmaktadır. Çok seviyeli eşiklemede eşik sayısı ne kadar artarsa hesaplama süresi de o oranda artacaktır. Hesaplama verimliliğini artırmak için çok seviyeli eşiklemede birçok yöntem önerilmiştir. Bu yöntemlerin, geleneksel Kapur ve Otsu yöntemleri ile karşılaştırıldığında çok seviyeli eşikleri belirlemede hesaplama karmaşıklığı büyük ölçüde azalttığı gösterilmiştir.

Manikandan ve diğerleri [11], Kapur'un entropi yöntemine dayalı çok seviyeli eşiklemeyi, simüle edilmiş ikili çaprazlama (Simulated Binary Crossover-SBX) ile kodlanmış genetik algoritma kullanarak gerçekleştirmişlerdir. Algoritma, manyetik rezonans beyin görüntülerinin bölütlenmesi amacıyla uygulanmıştır. Bulunan sonuçlar, Parçacık Sürü Optimizasyonu (Particle Swarm Optimization-PSO), bakteriyel yemleme optimizasyonu (Bacterial Foraging Optimization-BFO) ve uyarlamalı bakteriyel yemleme optimizasyonu (Adaptive Bacterial Foraging Optimization-ABFO) algoritmaları ile karşılaştırılmıştır ve genetik algoritmanın PSO, BF ve ABF optimizasyon yöntemlerinden daha iyi olduğu gösterilmiştir.

2018 yılında Agrawal vd. [12], çok seviyeli eşikleme için köşegen sınıf entropisi (diagonal class entropy - DCE) olarak adlandırılan yeni bir yaklaşım geliştirmişlerdir. Mercan resifi optimizasyon algoritması ile amaç fonksiyonu minimize ederek optimal eşik değerleri bulunmuştur. Amaç fonksiyonu DCE'den türetilmiştir ve DCE özellikleri ise gri seviye eş oluşum matrisinden (Giray Level Co-occurrence Matrix - GLCM) çıkarılmıştır. Önerilen yöntemin, 2-D Otsu'nun yönteminden ve diğer çok seviyeli eşikleme yöntemlerinden (Kapur'un Entropisi, Saliency Haritası [13], KL-MPSO [14], Entropi tabanlı [15]) üstün olduğu gösterilmiştir.

Pare ve diğerleri [16], GLCM'e dayalı renkli çok seviyeli eşikleme için yeni bir bölütleme yaklaşımı sunmuşlardır. GLCM'nin eksikliklerini (hesaplama karmaşıklığı ve kararlılık problemi) gidermek için en uygun eşik değerleri bulmada diferansiyel gelişim (Diferential Equation - DE) algoritması kullanmışlardır. Sunulan yöntemin diğer optimizasyon algoritmalarından (Geriye Dönük Arama Optimizasyonu Algoritması, PSO, BFO) ve geleneksel GLCM algoritmasından daha iyi performans gösterdiği sunulmuştur. Ayrıca kapsamlı enerji fonksiyonunu

kullanarak renkli çok seviyeli görüntü bölütlemesi için sürü tabanlı bir algoritma Pare ve diğerleri tarafından uygulanmıştır [17]. Shao vd. [18], farklı arama algoritmasına dayanan çok seviyeli eşikleme kullanarak ultrason görüntülerin bölütlenmesi için yeni bir yöntem önermişlerdir. Kapur'un entropisine dayalı çok seviyeli eşikleme ile uydu görüntülerinin bölütlenmesi için guguk kuşu ve rüzgar ile çalışan optimizasyon algoritması, Bhandari ve diğerleri tarafından uygulanmıştır [19]. Bao ve diğerleri tarafından çok seviyeli renkli görüntülerin bölütlenmesi için Harris Hawks (HH) ve DE optimizasyon algoritmalarının birleştirilmesiyle yeni bir hibrid algoritma gerçekleştirilmiştir [20].

[21]'te renkli görüntü bölütlemeyi iyileştirmek için kendinden uyarlamalı güve-alev optimizasyonu olarak adlandırılan yeni bir algoritma geliştirilmiştir. Amaç fonksiyonu olarak Kapur'un entropi yöntemi ve Otsu'nun eşikleme yöntemi kullanılmıştır. 6 doğal görüntü ve 4 tane uydu görüntüsü olmak üzere farklı eşik seviyelerine sahip 10 tane renkli görüntü kullanılmıştır. Bulunan sonuçlar, diğer sekiz meta sezgisel algoritma (multi-verse optimizer (MVO), balina optimizasyon algoritması, standart güve-alev optimizasyon algoritması, vs.) ile karşılaştırılmıştır ve kendinden uyarlamalı güve-alev optimizasyon algoritmasının diğer algoritmalara göre daha iyi olduğu gösterilmiştir. Pare vd. [22], farklı seviyelerdeki renkli görüntülerin çok seviyeli eşiklemesini gerçekleştirmek için değiştirilmiş bir bulanık entropi fonksiyonu sunmuşlardır. Optimal thresholding değerlerinin bulunmasında Levy uçuş güdümlü ateş böceği algoritması kullanılarak arama performansı dolayısıyla renkli görüntü bölütleme iyileştirilmeye çalışılmıştır. Ayrıca iki boyutlu histogramına dayalı görüntü bölütleme ile ilgili de pek çok çalışma yapılmıştır. Sarkar vd. [23], çok seviyeli eşikleme de iki boyutlu histogram tabanlı yaklaşımlardan daha üstün olduğunu göstermek için bir çalışma yapmışlardır. Ayrıca diferansiyel gelişim algoritmasının performansını diğer meta sezgisel algoritmalar (PSO, yapay arı koloni algoritması (Artificial Bee Colony - ABC), genetik algoritma, benzetimli tavlama algoritması) ile karşılaştırarak göstermişlerdir. Mittal ve Saraswat [24], yeni bir iki boyutlu histogram ve geliştirilmiş yer çekimi arama algoritması kullanarak çok seviyeli eşikleme yapmışlardır. Önerilen yöntemin deneysel sonuçları için, Berkeley ve Benchmark (BSDS300) veri seti, 3 seviye ve 5 seviyeli görüntü segmentasyonu için kullanılmıştır. Performans analizleri için ise ABC, yer çekimi arama algoritması (Gravitational Search Algorithm-GSA), Kaotik K_{best} yer çekimi arama algoritması (Chaotic K_{best} Gravitational Search Algorithm-cKGSA), DE algoritması ile karşılaştırmalı olarak 12 ölçü ve sonuç kullanılarak yapılmıştır. Borjigin ve Sahoo [25], gri seviye & yerel ortalama (gray level & local average-GLLA) histograma dayalı çok seviyeli eşikleme ile renkli görüntü bölütleme yapmışlardır.

Bu çalışmada gri seviyeli görüntüleri bölütlemek için çok seviyeli bir eşikleme yöntemi önerilmiştir. Önerilen metodun

etkililiği, BSDS300 veri seti üzerinde deneyler yapılarak görüntü bölütleme kalite ölçüm yöntemleri ile gösterilmiştir. Bu makalenin ana katkıları şu şekilde sıralanabilir:

- Yerel olmayan ortalama filtre tabanlı yeni bir iki boyutlu histogram yöntemi sunulmuştur,
- Maliyet fonksiyonu olarak iki boyutlu histogram da Renyi'nin entropisi çok seviyeli eşikleme için yeniden tanımlanmıştır,
- Hesaplama süresini azaltarak en uygun eşik değerlerini bulmak amacıyla PSO algoritması probleme uyarlanmıştır,
- Çok fazla ayrıntıya sahip görüntülerin bölütleme performansını artırmak amacıyla Renyi'nin entropisine dayalı 2DYOH-PSO çok seviyeli eşik belirleme yöntemi sunulmuştur,
- 2DYOH-PSO yöntemi, Berkeley-Benchmark veri setindeki görüntüler için uygulanan çok seviyeli eşiklemede 12 farklı kalite ölçüm endeksi (BDE, PRI, VOI, GCE, SSIM, FSIM, PSNR, RMSE, NAE, AD, MD) açısından oldukça başarılı olan GSA [26], ABC [27], DE [28], cKGSA [29] ve eKGSA [24] yöntemleri ile karşılaştırılarak daha etkin sonuçlar elde edildiği deneysel çalışmalar ile gösterilmiştir.

Makalenin organizasyonu şu şekildedir: Bölüm 2'de yaygın kullanılan eşikleme yöntemlerinden biri olan Renyi'nin Entropisi, Yerel olmayan ortalama filtre ve PSO algoritması incelenmiştir. Önerilen yöntem için iki boyutlu yerel olmayan ortalama histogram ve çok seviyeli eşikleme için Renyi'nin entropisi yeniden tanımlanarak, Bölüm 3'te verilmiştir. Bölüm 4'te, deneysel çalışmalarda kullanılan veri seti, önerilen yöntem için gerçekleştirilen algoritmanın uygulama adımları, algoritma parametrelerine değinilmiştir ve bölütleme başarımını ölçmek için kullanılan 12 kalite ölçüm indeksinden kısaca bahsedilmiştir. Deneysel sonuçlar ve diğer yöntemlerle elde edilen karşılaştırma tabloları Bölüm 5'te verilmiştir. Ve son olarak Bölüm 6'da, yapılan çalışmanın başarımları, eksiklikleri ve gelecekte yapılması hedeflenen çalışmalara değinilmiştir.

2. ÇOK SEVİYELİ GÖRÜNTÜ EŞİKLEME (MULTILEVEL IMAGE THRESHOLDING)

Çok seviyeli eşikleme, en çok kullanılan görüntü bölütleme yöntemlerinden birisidir. Verilen görüntünün histogramı çıkarıldıktan sonra Renyi'nin entropi yöntemine göre eşik değerleri bulunarak bölütleme işlemi gerçekleştirilir. Görüntü bölütleme de kullanılan pek çok metod hesaplama karmaşıklığından dolayı çok fazla zaman tüketmektedir. Ayrıca eşik seviye sayısı arttıkça uygulama daha karmaşık ve zaman alıcı hale gelmektedir. Hesaplama zamanını azaltmak ve eşikleme performansını iyileştirmek amacıyla PSO yönteminin hızlı yakınsama oranı dikkate alınarak bölütleme işlemi gerçekleştirilir.

2.1. Renyi'nin Entropisi (Renyi's Entropy)

Renyi'nin entropi yöntemi, ön plan ile arka plan arasındaki entropi farkını hesaplayarak optimal eşik değerini elde etmede kullanılır. $M \times N$ boyutlarında L gri seviyeli bir

görüntünün olasılık dağılımı $p_i = \{p_0, p_1, \dots, p_{L-1}\}$ şeklindedir ve $p_i = h_i/MxN$ olarak hesaplanmaktadır. Burada, h_i i . gri seviyedeki piksellerin tekrarlanma sıklığıdır. MxN ise görüntüdeki toplam piksel sayısıdır. İki seviyeli eşiklemede, görüntü ön plan ve arka olarak iki sınıfa ayrılır. t eşliğinde arka plan (Sınıf A) ve ön plan (Sınıf B) için entropiler; (Eş. 1, Eş. 2)

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

$$H_B = \frac{1}{1-q} \log \sum_{i=s}^{L-1} \sum_{j=t}^{L-1} \left(\frac{p_i}{P_B}\right)^q \quad (2)$$

eşitlikleri kullanılarak hesaplanmaktadır. Burada, q entropi indeksidir ve en uygun değeri 0,8 olarak verilmektedir [30]. Ön plan ve arka plan için olasılık dağılımları $P^A = \sum_{i=1}^t p_i$, $P^B = \sum_{i=t+1}^{L-1} p_i$ ve $p^A + p^B = 1$ şeklindedir. Renyi'nin toplam entropisi;

$$H = H_A + H_B \quad (3)$$

Eş. 3 kullanılarak elde edilir. Optimum eşik değeri ise;

$$T^* = \text{Arg max} (H_q) \quad (4)$$

Eş. 4 ile hesaplanır.

2.2. Yerel Olmayan Ortalama Filtre (Non-Local Means Filter)

$f(i)$; giriş görüntüsündeki i . pikselin gri seviye değeri olarak ifade edilirse, yerel olmayan filtredeki i . pikselin tahmini değeri, giriş görüntüsündeki diğer piksellerin ağırlıklandırılmış ortalaması olarak Eş. 5'te verildiği gibi ifade edilir [31]:

$$Y(x, y) = \sum_j w(i, j) \cdot f(j) \quad (5)$$

Burada, $w(i, j)$ değeri i ve j pikselleri arasındaki benzerliği gösteren ağırlık matrisi;

$$w(i, j) = \frac{1}{z_i} e^{-\frac{\|f(\mathcal{N}_i) - f(\mathcal{N}_j)\|^2}{h^2}} \quad (6)$$

şeklinde hesaplanır. Burada, h filtrenin derecesini, N_k ; sabit boyutlu ve k pikselinde ortalanmış karesel bir komşuluğu gösterir. $f(\mathcal{N}_i)$ ve $f(\mathcal{N}_j)$ ise gri seviye vektörlerinin yoğunluğunu ifade eder. Normalize edilmiş sabit z_i Eş. 7 ile bulunur.

$$z_i = \sum_j e^{-\frac{\|f(\mathcal{N}_i) - f(\mathcal{N}_j)\|^2}{h^2}} \quad (7)$$

i ve j pikseller arasındaki benzerlik, gri seviye vektörlerinin yoğunluk benzerliklerine dayalıdır. Bu benzerlik, Eş. 6'da görüldüğü gibi ağırlıklı Öklid mesafesinin azalan bir fonksiyonu olarak ölçülür. $f(\mathcal{N}_j)$ ile benzer gri düzey komşuluğuna sahip pikseller ortalama olarak daha büyük ağırlıklara sahiptir.

2.3. Parçacık Sürü Optimizasyon Algoritması (Particle Swarm Optimization Algorithm)

Parçacık sürü optimizasyon (Particle Swarm Optimization-PSO), sürü halinde yaşayan hayvanların davranışlarından esinlenilerek geliştirilmiş meta-sezgisel bir algoritmadır. Bu hayvanlar incelendiğinde yiyecek ararken etkileşim içerisinde oldukları ve birinin yiyecek bulması halinde diğer parçacıkların da konumlarını yiyeceğin olduğu yöne çevirdikleri ve hızlarını da yine yiyecek bulan parçacığa göre güncelledikleri görülmüştür. Bu sosyal etkileşim PSO ile modellenmiştir [32]. Parçacıkların hız ve pozisyonları;

$$v_{ij}(k+1) = v_{ij}(k) + C_1 \cdot \text{rand}_1 \left(P_{best,ij}(k) - x_{ij}(k) \right) + C_2 \cdot \text{rand}_2 (g_{best,ij}(k) - x_{ij}(k)) \quad (8)$$

$$x_{ij}(k+1) = x_{ij}(k) + v_{ij}(k+1) \quad (9)$$

eşitlikleri kullanılarak güncellenir. PSO algoritmasında p_{best} ve g_{best} olmak üzere iki önemli parametre mevcuttur. p_{best} , her bir parçacığın sahip olduğu en iyi pozisyonunu ifade ederken g_{best} , tüm parçacıkların içerisindeki en iyi pozisyonunu ifade eder.

3. ÖNERİLEN YÖNTEM (PROPOSED METHOD)

3.1. İki Boyutlu Yerel Olmayan Ortalama Histogram (Two Dimensional Non-Local Means Histogram)

f giriş görüntüsünün yerel olmayan ortalamalar ile filtrelenmiş görüntüsü g olsun ve MxN boyutlarındaki L gri seviyeli görüntünün $f(x,y)=i$ ve $g(x,y)=j$ deki toplam piksel sayısı h_{ij} olsun. Bu durumda, iki boyutlu yerel olmayan histogram,

$$p_{ij} = \frac{h_{ij}}{MxN} \quad (10)$$


Eş. 10 olarak tanımlanabilir. Burada p_{ij} 'deki $i=\{0,1,\dots,L\}$ ve $j=\{0,1,\dots,L\}$ 'dir ve LxL boyutlarında elde edilen P histogramı Şekil 1'de görülmektedir.

İki boyutlu olarak alınan eşik vektörü, histogramı 4 eşit parçaya ayırır. Burada, Bölge 1 ve 4 ön ve arka plan bilgisini bulundurunken Bölge 2 ve 3 gürültü ve kenar bilgisini içermektedir. Bu kapsamda, önerilen metodun hedefi olan nesnelere arka plandan ayırmak amacıyla sadece diagonal bölgeler dikkate alınmıştır.

3.2. Çok Seviyeli Eşikleme için Renyi'nin Entropisi (Renyi's Entropy for Multilevel Thresholding)

Bölütlenecek görüntü, $\{t_1, t_2, \dots, t_m\}$ eşik değerleri ile $\{s_1, s_2, \dots, s_m\}$ olmak üzere m sınıfa ayrılmış olsun. Bu durumda gri seviye sınıfları Eş. 11'de verilmiştir.

$$\begin{aligned} S_1 &= [0, \dots, t_1 - 1] \\ S_2 &= [0, \dots, t_2 - 1] \\ &\vdots \\ S_m &= [0, \dots, t_m - 1] \end{aligned} \quad (11)$$



Şekil 1. Yerel olmayan iki boyutlu histogram
(2D Non-local Means Histogram)

Buradan hareketle, Çok seviyeli eşikleme için Renyi'nin sınıf entropileri Eş. 12'de sunulmuştur:

$$H_0 = \frac{1}{1-q} \ln \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} \left(\frac{p_{ij}}{P_0}\right)^q$$

$$H_1 = \frac{1}{1-q} \ln \sum_{i=s}^{s_1-1} \sum_{j=t}^{t_1-1} \left(\frac{p_{ij}}{P_B}\right)^q$$

$$H_2 = \frac{1}{1-q} \log \sum_{i=s_1}^{s_2-1} \sum_{j=t_1}^{t_2-1} \left(\frac{p_{ij}}{P_B}\right)^q$$

$$\vdots$$

$$H_M = \frac{1}{1-q} \log \sum_{i=s_1}^{L-1} \sum_{j=t_1}^{L-1} \left(\frac{p_{ij}}{P_B}\right)^q \quad (12)$$

Renyi'nin toplam entropisi ise Eş. 13 ile hesaplanır.

$$H = \sum_{i=0}^m H_i \quad (13)$$

Optimum eşik değerleri Eş. 14 ile bulunur.

$$T^* = Arg \max(H) \quad (14)$$

4. DENEYSEL ÇALIŞMALAR (EXPERIMENTAL STUDIES)

Deneyle, 2,4 GHz, Intel^R core i7 işlemcili ve 8 GB RAM'a sahip bilgisayarda Matlab 2019a kullanılarak gerçekleştirilmiştir. Önerilen yöntem, BSDS300 veri seti içerisindeki görüntülere uygulanmıştır. Veri setinde 300 görüntü mevcuttur ve farklı kişiler tarafından yapılmış olan, her bir görüntüye ait 6 farklı referans görüntü bulunmaktadır. Kullanılan görüntüler 381x421 boyutlarındadır. Çalışmanın başarımı, veri seti içerisinde bulunan her bir görüntü için referans görüntüler kullanılarak değerlendirilir. Tablo 1'de önerilen yöntemin sözde kodu verilmektedir.

4.1. Parametrelerin Ayarlanması (Parameters Setting)

Parametrelerin değeri her algoritmanın performansını belirlemede önemli rol oynamaktadır. Bu makalede, tüm algoritmalar adil bir karşılaştırma için maksimum iterasyon sayısı, her algoritma için 1000 olarak alınmıştır. PSO algoritmasının parametreleri olan hızlandırma faktörleri *c1* ve *c2* ile momentum katsayısı (*w*) sırasıyla **0,12**, **1,2** ve **0,9** olarak uygulama için en uygun değerleri sağlayacak şekilde seçilmiştir. Önerilen yöntem için kullanılan tüm algoritma parametreleri Tablo 2'de verilmiştir.

Tablo 1. Önerilen Yöntemin Sözde Kodu (Pseudo Code of the Proposed Method)

Giriş: Veri seti içerisindeki görüntüler ($f^1, f^2, f^3, \dots, f^{300}$)
Çıkış: 12 kalite ölçüm indeksi, bölütlenen görüntüler ($g^1, g^2, g^3, \dots, g^{300}$)
1 : for görüntü sayısı
2 : Eş. 10 kullanarak her bir f^n görüntüsünün histogramını hesapla
3 : Bölütlenecek giriş görüntüsü f^n için eşik seviye sayısını belirle
4 : Görüntü histogramını ve eşik seviye sayısını optimizasyon algoritmasına gönder
a. Başlangıç algoritma parametreleri olan atalet faktörü (<i>w</i>), hızlandırma faktörleri (<i>c1</i> , <i>c2</i>), popülasyondaki parçacık sayısı (<i>N</i>), iterasyon sayısı değerlerini belirle.
b. D-boyutlu arama uzayında başlangıç popülasyonunu oluştur $P = \{X_1, X_2, X_3, \dots, X_N\}$
c. for maksimum iterasyon sayısı
i. Her bir <i>X</i> parçacığının uygunluk değerini, Renyi'nin Entropi yöntemine göre hesapla
ii. En iyi yerel değerlerini- p_{best} , önceki p_{best} değerleri ile karşılaştırarak güncelle.
iii. Partiküllerin lokal en iyi pozisyonlarını birbirleri ile karşılaştır ve en iyi p_{best} değerini küresel en iyi g_{best} olarak ata. Her iterasyonda g_{best} değerini güncelle.
iv. Parçacıkların hız ve pozisyonlarını Eş. 8 ve Eş. 9'u kullanarak güncelle.
d. end for
e. Bulunan eşik değerleri giriş görüntüsüne uygula.
5 : Bulunan optimal eşik değerini ve eşik değerine ait maksimum entropiyi sakla.
6 : end for
7 : Eşik değerleri giriş görüntüsüne uygula.
8 : Bölütlenen görüntüleri veri setinde bulunan referans görüntüler ile karşılaştır.
9 : Belirli kalite ölçüm indeksleri kullanarak bölütlenen görüntünün başarımını değerlendir.
10 : Return kalite ölçüm değerleri ve bölütlenen görüntüler

Tablo 2. Çok seviyeli eşikleme için kullanılan algoritma parametreleri
(The parameters of the algorithm for multilevel thresholding)

Parametreler	Değerleri
Parçacıkların boyutu	Eşikleme seviyesi
Alt sınır	0
Üst sınır	255
Sürüdeki parçacık sayısı	100
Popülasyon boyutu	Parçacık boyutu * parçacık sayısı
İterasyon sayısı	1000
Hızlandırma faktörleri ($c1, c2$)	0,12,1,2
Momentum katsayısı (w)	0,9
Eşik seviye sayıları	3 seviye, 5 seviye

Önerilen yöntemde, oluşturulan popülasyondaki parçacıkların boyutu görüntüye uygulanacak eşik seviyesine göre belirlenmektedir. Beş seviyeli görüntü eşikleme için her bir parçacık boyutu 5×1 ve 100 parçacıktan oluşan popülasyon boyutu 5×100 şeklinde olacaktır. Oluşturulan popülasyondaki parçacıklar $[0,255]$ arasında değerler almaktadır.

4.2. Kalite Ölçüm İndeksleri (Quality Measurement Indexes)

Görüntülerin bölütlenmesi işleminin ne ölçüde başarılı olduğunu belirlemek amacıyla yapılandırılmış benzerlik indeksi, özellik benzerlik indeksi, tepe sinyal-gürültü oranı, rastgele olasılık indeksi, çapraz korelasyon, bilgi varyasyonu, sınır yer değiştirme hatası, global tutarlılık hatası, ortalama karesel hata gibi ölçüm indeksleri yaygın olarak kullanılmaktadır.

4.2.1. Yapılandırılmış benzerlik indeksi (Structured similarity index -SSIM)

SSIM indeksi, orijinal resim ile bölütlenen resim arasındaki benzerliği ölçer. SSIM değerinin yüksek olması daha iyi bir performansını ifade eder [33]. SSIM değeri;

$$SSIM(x, y) = \frac{(2\mu_x\mu_y+c_1)(2\sigma_{xy}+c_2)}{(\mu_x^2+\mu_y^2+c_1)(\sigma_x^2+\sigma_y^2+c_2)} \quad (15)$$

Eş. 15 ile hesaplanmaktadır.

4.2.2. Özellik benzerlik indeksi (Feature similarity index -FSIM)

FSIM indeksi, orijinal resim ile bölütlenen resim arasındaki benzerliği değerlendiren ölçüm birimidir. FSIM değeri $[-1,1]$ aralığındadır. Yüksek FSIM değeri daha iyi eşikleme yapıldığını göstermektedir. Eşik seviyesi arttıkça bu değerler de artış göstermektedir [34]. FSIM değeri;

$$FSIM(x, y) = \frac{\sum_{x \in \Omega} S_L(X)PC_m(X)}{\sum_{x \in \Omega} PC_m(x)} \quad (16)$$

Eş. 16 olarak elde edilir.

4.2.3. Tepe sinyal-gürültü oranı (Peak signal to noise ratio -PSNR)

PSNR farklı dinamik aralıklara sahip görüntüleri karşılaştırmak için kullanılmaktadır. Yüksek PSNR değeri

daha iyi bir eşikleme performansını ifade eder [35]. PSNR değeri: (Eş. 17)

$$PSNR = 10 \log_{10} \frac{(2^b-1)^2}{\sqrt{MSE}} \quad (17)$$

4.2.4. Olasılık rand endeksi (Probability rand index -PRI)

İki görüntü arasındaki benzerlik ölçümünde kullanılır. Genellikle $[0,1]$ aralığında değer almaktadır. Yüksek PRI değeri iyi bir eşikleme performansını göstermektedir [36]. PRI değeri: (Eş. 18)

$$PRI = \frac{a+b}{a+b+c+d} \quad (18)$$

$a + b$ ifadesi iki görüntü arasındaki benzer piksellerin sayısı, $c + d$ ifadesi iki görüntü arasındaki farklı piksellerin sayısıdır.

4.2.5. Çapraz korelasyon (Cross correlation -CC)

Eşik sayısı arttıkça CC değeri de artış gösterir. Yüksek CC değeri iyi bir eşikleme performansını göstermektedir [35]. (Eş. 19)

$$CC = \frac{1}{n} \sum_{\sigma_x \sigma_y} (X(x, y) - \bar{X})(Y(x, y) - \bar{Y}) \quad (19)$$

4.2.6. Bilgi varyasyonu (Variation of information -VOI)

VOI, ortalama koşullu entropi cinsinden iki bölütleme arasındaki mesafeyi tanımlayarak bölütlenmiş bir görüntüdeki rastgelelik miktarını hesaplar [36]. VOI değeri;

$$VOI(X; Y) = H(X) + H(Y) - 2I(X, Y) \quad (20)$$

Eş. 20 olarak hesaplanır. Burada, $H(X)$ ifadesi, X in entropisini, $I(X, Y)$ ifadesi ise X ile Y arasındaki ortak bilgidir. VOI, $[0, \infty)$ aralığında değer alır. Daha iyi bölütleme için küçük VOI değeri tercih edilir.

4.2.7. Sınır yer değiştirme hatası (Boundary displacement error -BDE)

BDE, bölütlenmiş görüntüler arasında sınır piksellerin yer değiştirmesinin ortalama hatasını hesaplar. Diğer görüntü sınırındaki piksel ile en yakın piksel arasındaki mesafe olarak tanımlanır. Daha iyi bölütleme için daha düşük bir BDE değeri tercih edilir [36]. (Eş. 21)

$$BDE = \begin{cases} \frac{u-v}{L-1}, & 0 < (u - v) \\ 0, & u - v < 0 \end{cases} \quad (21)$$

4.2.8. Global tutarlılık hatası (Global consistency error - GCE)

GCE bir bölütlemenin, diğerinin bir gelişimi olarak ne ölçüde gözlenebileceğini hesaplar. GCE endeksi (0,1) aralığındadır [36]. Değer ne kadar küçükse, bölütleme o kadar iyi olur. GCE değeri Eş. 22 olarak hesaplanır.

$$GCE = \frac{1}{n} \{ \sum_i E(S_1, S_2, p_i), \sum_i E(S_2, S_1, p_i) \} \quad (22)$$

4.2.9. Ortalama karesel hata (Mean square error - MSE)

Endeks, hatanın karesinin ortalamasını ölçmektedir. Düşük MSE değerleri iyi bir görüntü bölütlemesi yapıldığını gösterir [35]. MSE denklemi Eş. 23’de verilmiştir.

$$MSE = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \|x(i, j) - y(i, j)\|^2 \quad (23)$$

Burada, M ve N görüntünün boyutlarını temsil etmektedir. X orijinal görüntü ve Y bölütlenmiş görüntüyü göstermektedir.

4.2.10. Ortalama fark (Average difference- AD)

AD, referans görüntü ve bölütlenmiş görüntü arasındaki farkın ortalamasıdır. Daha iyi bir bölütleme için düşük AD değeri tercih edilir [35]. AD değeri Eş. 24 ile hesaplanır.

$$AD = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (x(i, j) - y(i, j)) \quad (24)$$

4.2.11. Maksimum fark (Maximum difference- MD)

MD, iki görüntü arasındaki hatanın maksimumunu alır. MD değerinin küçük olması, daha iyi bölütlemeyi ifade eder [35]. MD eşitliği Eş. 25 olarak verilir.

$$MD = \max |x(i, j) - y(i, j)| \quad (25)$$

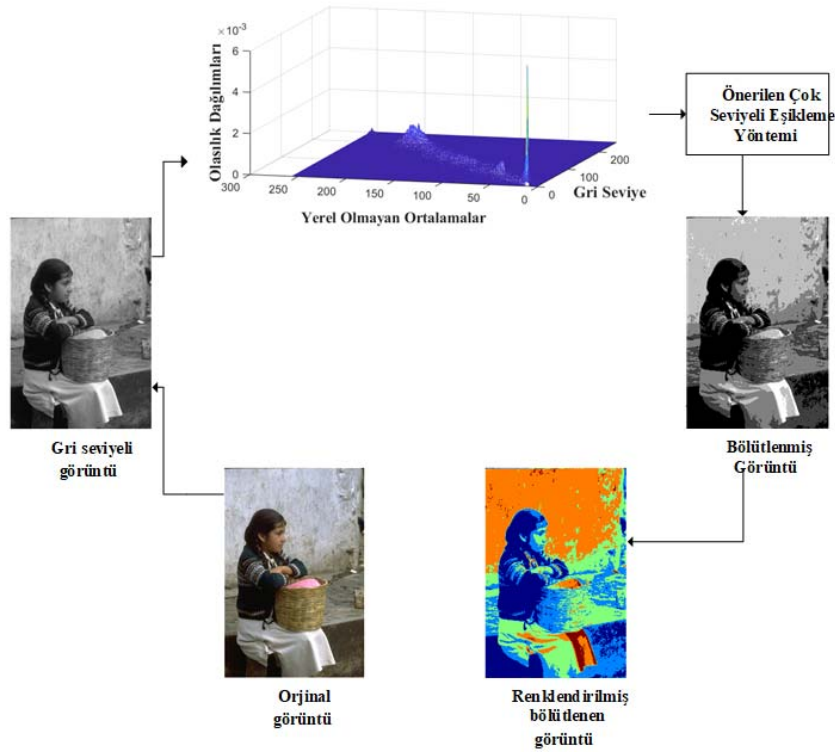
4.2.12. Normalize edilmiş mutlak fark (Normalized absolute error- NAE)

NAE, iki görüntü arasındaki normalleştirilmiş mutlak farkı hesaplar. iyi bölütleme için Düşük NAE değeri tercih edilir [24]. Değeri Eş. 26 ile hesaplanır.


$$NAE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |x(i, j) - y(i, j)| \quad (26)$$

5. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Belirtilen veri setinde eğitim ve test verisi olarak ayrı ayrı bulunan 300 görüntüye farklı seviyelerde eşikleme yapılmıştır. Yapılan eşiklemenin başarımını değerlendirmek için 12 kalite ölçüm yöntemi uygulanmıştır. Önerilen yöntem ile bölütleme işlem adımlarını gösteren akış şeması Şekil 2’de verilmiştir.



Şekil 2. Önerilen yöntemin akış şeması (The Flow Chart of the Proposed Method)



Şekil 3. Önerilen çok seviyeli eşikleme yönteminin analizi (Analysis of the proposed multi-level thresholding method)

Tablo 3. 3 seviyeli görüntü eşikleme ile önerilen yöntemin diğer yöntemlerle karşılaştırması (Comparison of the proposed method with 3-level image thresholding with other methods)

YÖNTEM	Önerilen Yöntem	GSA	cKGSA	eKGSA	DE	ABC
BDE	9,9713	10,2567	10,2719	10,2407	10,4109	10,456
PRI	0,6130	0,6073	0,6070	0,6079	0,5993	0,6016
VOI	2,8057	2,8067	2,8060	2,8078	2,7882	2,7828
GCE	0,3391	0,3348	0,3345	0,3352	0,3247	0,3238
SSIM	0,5258	0,4529	0,4529	0,4549	0,4423	0,4398
FSIM	0,5902	0,6749	0,6742	0,6779	0,6697	0,6691
RMSE	43,3015	50,0514	50,0259	49,8913	51,1517	51,7063
PSNR	15,6764	14,4014	14,4092	14,4306	14,2079	14,1617
CC	0,8824	0,6414	0,6517	0,6532	0,6414	0,6369
AD	36,7691	42,7436	42,7141	42,5637	43,7985	44,2451
MD	94,5	110,902	110,925	110,8570	111,107	113,715
NAE	0,367	0,4100	0,4099	0,4080	0,422	0,4257

Verilen orjinal renkli görüntü gri seviyeye dönüştürülüp histogramı çıkarılır. Hesaplanan histograma, PSO optimizasyon yöntemi ile Renyi yöntemine dayalı eşikleme yapıp bulunan optimal eşik değerlerine göre görüntü bölütlenir. Önerilen görüntü bölütleme yöntemi BSDS300 veri setinden rastgele seçilen bir görüntü için uygulanmıştır

ve bölütlenen görüntüler, Mittal ve Saraswat tarafından yapılan çalışma [24] ile karşılaştırmalı olarak Şekil 3'de verilmiştir. Belirtilen kalite ölçüm yöntemleri, veri setinde bulunan tüm görüntülere ayrı ayrı uygulanmıştır ve ortalama değerleri hesaplanarak sonuçları verilmiştir. Önerilen yöntem ile görüntülere 3 seviyeli eşikleme uygulandığında

elde edilen ortalama kalite ölçüm değerleri, diğer meta sezgisel yöntemler olan yerçekimi arama algoritması (GSA) [26], yapay arı algoritması (ABC), diferansiyel gelişim algoritması (DE), kaotik K_{best} yerçekimi arama algoritması (cKGSA) [29], üstel K_{best} yerçekimi arama algoritması (eKGSA) [24] gibi yöntemlerle karşılaştırmalı olarak Tablo 3’de verilmiştir.

Önerilen yöntem ile görüntülere 5 seviyeli eşikleme uygulandığı durumda ise elde edilen ortalama kalite ölçüm değerleri, belirtilen diğer meta sezgisel yöntemlerin sonuçları ile karşılaştırmalı olarak Tablo 4’de verilmiştir.


Tablo 3 ve Tablo 4 incelendiğinde önerilen bölütleme metodu ile yapılan çok seviyeli eşikleme işlemi için hesaplanan BDE değerinin hem 3 seviyeli hem de 5 seviyeli eşikleme de diğer yöntemlere göre daha küçük olduğu görülmektedir. BDE değeri, bölütlenmiş görüntü ile referans görüntü arasındaki minimum sapmayı ifade etmektedir. Bu değer ne kadar küçük olursa o kadar iyi bir bölütleme yapıldığı anlamına gelmektedir. BSDS300 veri seti içerisinde rastgele seçilen bir görüntüye ait referans görüntüler ve önerilen metod ile bölütlenmiş görüntüler Şekil 3’de karşılaştırmalı olarak verilmiştir. PRI değeri bölütleme kararlılığını göstermektedir. 3 seviyeli bölütleme de önerilen

yöntem diğerlerine göre daha iyi sonuç verirken 5 seviyeli eşikleme de PRI, VOI ve GCE değerlerinin rekabetçi sonuçlar ürettiği görülmektedir. RMSE, AD, MD, NAE indeksleri istatistiksel hata parametreleri olup 3 seviyeli bölütleme için önerilen yöntemle bulunan sonuçların diğer yöntemlerden daha üstün olduğu görülmektedir. PSNR değeri ise RMSE değeri ile ters orantılı olup yüksek değerlerinde daha iyi bölütleme yapıldığını göstermektedir. SSIM ve FSIM değerleri görüntü kalitesinin göstergeleridir. 5 seviyeli bölütleme de her iki değer de iyi çıkması yapılan görüntü bölütlemenin kalitesini göstermektedir. Sonuç olarak Tablo 3 ve Tablo 4’de önerilen bölütleme metodu ile 3 seviyeli ve 5 seviyeli olarak yapılan eşikleme işlemlerinde önerilen yöntemin diğer yöntemlere göre daha iyi olduğu açık bir şekilde görülmektedir.

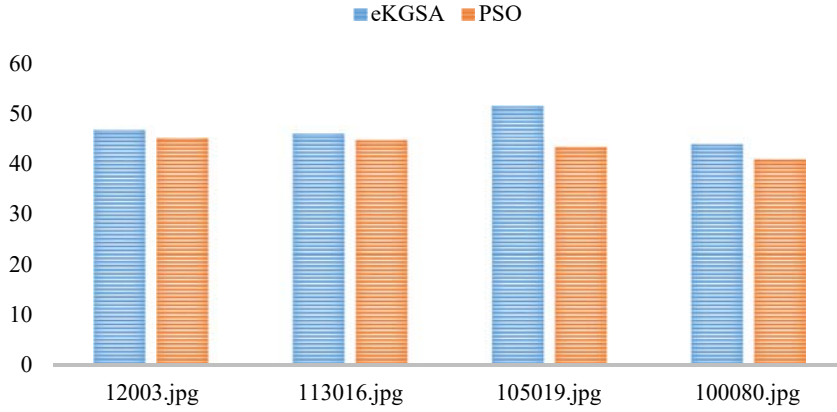
Üç seviyeli eşikleme için önerilen yöntemde kullanılan PSO algoritması ile e-KGSA algoritmasının uygun eşik değerlerini hesaplama süreleri karşılaştırmalı olarak Şekil 4’de verilmiştir. Aynı şekilde, PSO, e-KGSA algoritmaları kullanılarak 5 seviyeli eşiklemede uygun eşik değerlerini hesaplama süreleri karşılaştırmalı olarak Şekil 5’de verilmiştir. Her iki çok seviyeli eşikleme için de PSO yönteminin diğer yöntemlere göre hesaplama süresinin daha az olduğu belirtilen şekillerde görülmektedir.

Tablo 4. 5 seviyeli görüntü eşikleme ile önerilen yöntemin diğer yöntemlerle karşılaştırması
(Comparison of the proposed method with 5-level image thresholding with other methods)

Yöntem	Önerilen Yöntem	GSA	cKGSA	eKGSA	DE	ABC
BDE	9,7782	9,9448	9,8978	9,8776	10,0865	9,9355
PRI	0,6591	0,6610	0,7010	0,7261	0,645	0,6553
VOI	3,0255	3,1415	3,1419	3,1436	3,0676	3,1283
GCE	0,4401	0,4396	0,4391	0,4397	0,4124	0,4332
SSIM	0,6654	0,6566	0,6569	0,6428	0,598	0,6428
FSIM	0,791	0,7857	0,7858	0,78	0,7549	0,6428
RMSE	29,2333	29,3868	29,4240	29,3922	35,1074	30,9452
PSNR	19,0404	18,9516	18,9410	18,9463	17,565	18,596
CC	0,9743	0,8006	0,8004	0,8	0,7629	0,7888
AD	24,6882	24,9333	24,9601	24,899	29,4665	26,1351
MD	71,55	69,5218	69,8932	70,1836	79,7659	73,2606
NAE	0,2427	0,2419	0,2420	0,2412	0,2878	0,2557



Şekil 4. 3 seviyeli eşik için PSO ve e-KGSA tarafından elde edilen hesaplama süresinin karşılaştırılması
(Comparison of calculation time computed by PSO and e-KGSA for 3-level thresholding)



Şekil 5. 5 seviyeli eşik için PSO ve e-KGSA tarafından elde edilen hesaplama süresinin karşılaştırılması
(Comparison of calculation time computed by PSO and e-KGSA for 5-level thresholding)

6. SONUÇLAR (CONCLUSIONS)

Görüntü bölütleme, uzun yıllardır çalışılan bir konu olmasına rağmen yapılan çalışmaların başarımları görüntüden görüntüye ve uygulamaya dayalı olarak değişiklikler göstermektedir. Bu sebeple görüntü bölütleme hala geliştirilmesi gereken bir alan olarak görülmektedir ve her geçen gün yeni yöntemler üzerinde çalışılmaktadır.

Bu makalede, gri seviyeli görüntüler için yerel olmayan ortalama filtre tabanlı iki boyutlu histogram yöntemi kullanılarak çok seviyeli bir görüntü bölütleme yöntemi önerilmiştir. Maliyet fonksiyonu olarak iki boyutlu histogram da Renyi'nin entropisi çok seviyeli eşikleme için yeniden tanımlanmıştır ve hesaplama süresini azaltarak en uygun eşik değerlerini bulmak amacıyla PSO algoritması probleme uyarlanmıştır. Görüntülerin bölütleme performansını artırmak amacıyla Renyi'nin entropisine dayalı 2DYOH-PSO çok seviyeli eşik belirleme yöntemi sunulmuştur. Tablo 3 ve Tablo 4 incelendiğinde 2DYOH-PSO ile 3 seviyeli eşikleme işlemi gerçekleştirdiği durumda, mevcut 5 farklı yöntem ile 12 performans değerlendirme indeksi bakımından yapılan bölütleme işlemlerinin başarımları BDE; %2,63 oranında, PRI; %0,83 oranında SSIM; %15,5 oranında, RMSE; %13,2 oranında, PSNR; %8,63, CC; %35 oranında, AD; %13,9 oranında, MD; %14,75, NAE %10 oranında iyileşme sağlanmıştır. 2DYOH-PSO ile 5 seviyeli eşikleme işlemi gerçekleştirildiği durumda ise Berkeley-Benchmark veri setindeki görüntülerin bölütlenmesinde ki başarımın BDE; %1, FSIM; %0,85 oranında, RMSE; %15,35 oranında, PSNR; %8,88, CC; %17,36 oranında, AD; %12,8 oranında iyileştiği deneysel sonuçlar ile gösterilmiştir.

Gelecek çalışmalarda, daha ayrıntılı görüntülerin bölütlenmesinde kullanılan çok seviyeli eşikleme yöntemlerindeki hesaplama karmaşıklığını azaltmak amacıyla eşik seviye sayısını adaptif olarak hesaplayabilen algoritmalar geliştirilmeye çalışılacaktır. Böylece daha hassas bir bölütleme gerçekleştirilmesi hedeflenmektedir. Ayrıca, enerji tabanlı eşikleme yöntemler [17], bulanık entropi [22], köşegen sınıf entropisi gibi farklı yöntemler

üzerinde çalışmalar genişletilerek görüntüler için daha optimum eşik değerleri ile daha hassas doğrulukta bölütleme sağlanması amacıyla adaptif yöntemlerin geliştirilmesi amaçlanmaktadır. Bunların yanı sıra önerilen yöntem ve gelecekte geliştirilecek yöntemler uydu görüntüleri, tıbbi görüntüler, doğa görüntüleri, gerçek zamanlı görüntüler gibi farklı uygulama alanları için de sınanacaktır.

KAYNAKLAR (REFERENCES)

1. Bilge H., Verim V., Prostate Contour Extraction from Ultrasound Images, Journal of the Faculty of Engineering and Architecture of Gazi University, 22 (3), 407-413, 2013.
2. Kasim Ö., Kuzucuoğlu A.E., Detection and Classification of Leukocyte Cells from Smear Image, Journal of the Faculty of Engineering and Architecture of Gazi University, 30 (1), 95-109, 2015.
3. Küçük H., Eminoğlu İ., Balcı K., Classification of neuromuscular diseases with artificial intelligence methods, Journal of the Faculty of Engineering and Architecture of Gazi University. 34 (4), 1725-1741, 2019.
4. Alkan A., Selcuk T., Çolakoğlu A.S., Bread texture analysis and development of user interface using image processing techniques, Journal of the Faculty of Engineering and Architecture of Gazi University, 33 (1), 31-41, 2018.
5. Demirhan A., Güler İ., Image Segmentation Using Self-Organizing Maps and Gray Level Co-Occurrence Matrices, Journal of the Faculty of Engineering and Architecture of Gazi University, 25 (2), 285-291, 2010.
6. Karaca A.C., Güllü M.K., Detection of forest fire in Menderes district using a superpixel segmentation based search method, Journal of the Faculty of Engineering and Architecture of Gazi University, 34 (2), 1061-1076, 2019.
7. Kaya H., Çavuşoğlu A., Çakmak H.B., Şen B., Delen D., Supporting the diagnosis process and processes after treatment by using image segmentation and image simulation techniques: Keratoconus example, Journal of

- the Faculty of Engineering and Architecture of Gazi University, 31 (3), 737–747, 2016.
8. Sezgin M., Sankur B., Survey over image thresholding techniques and quantitative performance evaluation, *J. Electron. Imaging*, 13, 146–165, 2004.
 9. Nobuyuki O., A Threshold Selection Method from Gray-Level Histograms, *IEEE Trans. Syst., Man, Cybern.*, 9, 62–66, 1979.
 10. Kapur J. N., Sahoo P. K., Wong A. K. C., A new method for gray-level picture thresholding using the entropy of the histogram, *Computer Vision, Graphics, and Image Processing*, 29, 273–285, 1985.
 11. Manikandan S., Ramar K., Willjuice Iruthayarajan, M., Srinivasagan, K.G., Multilevel thresholding for segmentation of medical brain images using real coded genetic algorithm, *Measurement*, 47, 558–568, 2014.
 12. Agrawal S., Panda R., Abraham A., A Novel Diagonal Class Entropy-Based Multilevel Image Thresholding Using Coral Reef Optimization, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 1–9, 2018.
 13. Achanta R., Estrada F., Wils P., Süsstrunk S., Salient Region Detection and Segmentation, In: *Computer Vision Systems*, 66–75. Berlin, Heidelberg, 2008.
 14. Zhao X., Turk M., Li W., Lien K., Wang G., A multilevel image thresholding segmentation algorithm based on two-dimensional K–L divergence and modified particle swarm optimization, *Applied Soft Computing*, 48, 151–159, 2016.
 15. Ben İshak A., A two-dimensional multilevel thresholding method for image segmentation, *Applied Soft Computing*, 52, 306–322, 2017.
 16. Pare S., Kumar A., Singh G. K., Color multilevel thresholding using gray-level co-occurrence matrix and differential evolution algorithm, 2017 International Conference on Communication and Signal Processing (ICCSP), India, April 6, 2017.
 17. Pare S., Kumar A., Bajaj V., Singh G.K., A context sensitive multilevel thresholding using swarm based algorithms, *IEEE/CAA Journal of Automatica Sinica*, 6, 1471–1486, 2019.
 18. Shao D., Xu C., Xiang Y., Gui P., Zhu X., Zhang C., Yu Z., Ultrasound image segmentation with multilevel threshold based on differential search algorithm, *IET Image Processing*, 13, 998–1005 2019.
 19. Bhandari A.K., Singh V.K., Kumar A., Singh G.K., Cuckoo search algorithm and wind driven optimization based study of satellite image segmentation for multilevel thresholding using Kapur’s entropy, *Expert Systems with Applications*, 41, 3538–3560, 2014.
 20. Bao X., Jia H., Lang C., A Novel Hybrid Harris Hawks Optimization for Color Image Multilevel Thresholding Segmentation, *IEEE Access*, 7, 76529–76546, 2019.
 21. Jia H., Ma J., Song W., Multilevel Thresholding Segmentation for Color Image Using Modified Moth-Flame Optimization, *IEEE Access*, 7, 44097–44134, 2019.
 22. Pare, S., Bhandari, A.K., Kumar, A., Singh, G.K., A new technique for multilevel color image thresholding based on modified fuzzy entropy and Lévy flight firefly algorithm, *Computers & Electrical Engineering*, 70, 476–495, 2018.
 23. Sarkar S., Das S., Multilevel Image Thresholding Based on 2D Histogram and Maximum Tsallis Entropy— A Differential Evolution Approach, *IEEE Transactions on Image Processing*, 22, 4788–4797, 2013.
 24. Mittal, H., Saraswat, M., An optimum multi-level image thresholding segmentation using non-local means 2D histogram and exponential Kbest gravitational search algorithm, *Engineering Applications of Artificial Intelligence*, 71, 226–235, 2018.
 25. Borjigin S., Sahoo P.K., Color image segmentation based on multi-level Tsallis–Havrda–Charvát entropy and 2D histogram using PSO algorithms, *Pattern Recognition*, 92, 107–118, 2019.
 26. Rashedi E., Nezamabadi-pour H., Saryazdi S., GSA: A Gravitational Search Algorithm, *Information Sciences*, 179, 2232–2248, 2009.
 27. Akay B., A study on particle swarm optimization and artificial bee colony algorithms for multilevel thresholding, *Applied Soft Computing*, 13, 3066–3091, 2013.
 28. Sarkar S., Das S., Chaudhuri S.S., A multilevel color image thresholding scheme based on minimum cross entropy and differential evolution, *Pattern Recognition Letters*, 54, 27–35, 2015.
 29. Mittal H., Pal R., Kulhari A., Saraswat M., Chaotic Kbest gravitational search algorithm (CKGSA), Ninth International Conference on Contemporary Computing (IC3), 1–6, IEEE, Noida, India, 2016.
 30. Liang H., Jia H., Xing Z., Ma J., Peng X., Modified Grasshopper Algorithm-Based Multilevel Thresholding for Color Image Segmentation, *IEEE Access*, 7, 11258–11295, 2019.
 31. Buades A., Coll B., Morel J. M., A Non-Local Algorithm for Image Denoising, 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05), 60–65, IEEE, San Diego, CA, USA, 2005.
 32. Erdo P., Yalçın E., The Solutions of Unconstrained Optimization Benchmark Problems with Particle Swarm Optimization, 4, 14–22, 2015.
 33. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P., Image Quality Assessment: From Error Visibility to Structural Similarity, *IEEE Trans. on Image Process*, 13, 600–612, 2004.
 34. Zhang L., Zhang L., Mou X., Zhang D., FSIM: A Feature Similarity Index for Image Quality Assessment, *IEEE Transactions on Image Processing*, 20, 2378–2386, 2011.
 35. Sasi varnan C., Jagan A., K.J., Jyoti D., Rao Dr.D.S., Image Quality Assessment Techniques pn Spatial Domain, *International Journal of Computer Science and Technology*, 2, 177–184 (2011).
 36. Sathya, B., Manavalan R., Image Segmentation by Clustering Methods: Performance Analysis. *International Journal of Computer Applications*, 29, 27–32, 2011.