



Görüntü İkileştirme için Global Eşikleme Yöntemleri Üzerine Bir İnceleme

A Review on Global Thresholding Methods for Image Binarization

Abdullah Elen 

Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Yazılım Mühendisliği Bölümü, Bandırma, Balıkesir/TÜRKİYE

aelen@bandirma.edu.tr

Araştırma Makalesi/Research Article

ARTICLE INFO

Article history

Received: 2 September 2020

Accepted: 14 September 2020

Keywords:

Image Processing, Global Thresholding, Binarization

ABSTRACT

Thresholding is one of the most essential issues in image processing. Although this technique is commonly used for segmentation of regions with different homogeneity in grayscale images, and it is also preferred for segmentation of colored images. In this study, 14 different algorithms capable of global thresholding on gray-scale images were categorized and examined in detail as cluster-based, entropy-based, shape-based and feature similarity-based. To test the performance of the algorithms, a dataset consisting of 15 different images was prepared. For these images, the threshold value was determined manually by four experts and reference binary images were obtained by calculating mean value. Accordingly, the binary images produced by each algorithm were examined with the similarity rates to the reference images using the Jaccard Index method. In experimental studies, it was seen that the highest score according to the average similarity ratio obtained belongs to the IsoData and Otsu algorithms with approximately 95%.

© 2020 Bandırma Onyedi Eylül University, Faculty of Engineering and Natural Science. Published by Dergi Park. All rights reserved.

MAKALE BİLGİSİ

Makale Tarihleri

Gönderim: 2 Eylül 2020

Kabul: 14 Eylül 2020

Anahtar Kelimeler:

Görüntü İşleme, Global Eşikleme, İkileştirme

ÖZET

Görüntü işlemede en temel konulardan biri eşikleme yöntemidir. Bu yöntem, yaygın olarak gri tonlamalı görüntülerdeki farklı homojenliğe sahip bölgelerin bölütlenmesinde kullanılmakla birlikte renkli görüntülerin bölütlenmesi için de tercih edilir. Bu çalışmada, gri ölçekli görüntüler üzerinde global eşikleme yapabilen 14 farklı algoritma; kümeleme tabanlı, entropi tabanlı, şekil tabanlı ve öznelik benzerliğine dayalı olmak üzere kategorize edilmiş ve detaylı olarak incelenmiştir. Algoritmaların performansını test etmek için 15 farklı görüntüden oluşan bir veri seti hazırlanmıştır. Bu görüntüler için dört uzman tarafından el yordamıyla eşik değeri belirlenmiş ve ortalama değeri alınarak referans ikili görüntüler elde edilmiştir. Buna göre her bir algoritmanın ürettiği ikili görüntüler, Jaccard Index yöntemiyle referans görüntülere olan benzerlik oranları incelenmiştir. Deneysel çalışmalarda, elde edilen benzerlik oranı ortalamasına göre en yüksek skor yaklaşık %95 ile IsoData ve Otsu algoritmalarına ait olduğu görülmüştür.

© 2020 Bandırma Onyedi Eylül Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi. Dergi Park tarafından yayınlanmaktadır. Tüm Hakları Saklıdır.

1. GİRİŞ

Eşikleme, görüntü bölütleme amacı için kullanılan en önemli yaklaşımlardan birisidir [1] ve birçok görüntü analizi uygulamasında ön işlem olarak tercih edilir. Örneğin medikal görüntü işleme, belge görüntülerinin analizi, doku analizi, nesne algılama, parmak izi ve yüz tanıma, haritalar, çizimler vb. birçok alanda problemlerin çözümü için temel yapı niteliğindedir [2, 3]. Burada amaç, uygun bir eşik değeri kullanarak görüntü içerisindeki nesnelere arka plandan ayırmaktır [4]. Global algoritmalar, eşik değerini belirlemek için tüm görüntü bilgilerini kullanır ve görüntüdeki tüm piksellere eşit olarak uygulanır [5]. Otomatik eşiklerin temel avantajı, görüntü değişimlerini hesaba katmaları ve kullanıcı önyargısız birçok görüntüyü toplu işlenmesini kolaylaştırmasıdır. Eşik, verilerin karmaşıklığını azaltan, tanıma ve sınıflandırma vb. süreçlerde işlem kolaylığı sağlayan ikili (*Binary*) bir görüntü üretilmesini mümkün kılar. Eşikleme, görüntünün birden fazla özelliğini kullanarak bölütleme gerçekleştiren yöntemlere kıyasla daha hızlı sonuç verir [6]. Optimal eşik değerinin tespit edilmesinde, yaygın olarak görüntüdeki gri seviye dağılımlarını gösteren bir histogramdan faydalanılır [7]. Bu durumda nesnelere arka plandan ayırmak için en kolay yol, histogramdan göreceli olarak belirlenen bir T eşik değeri ile görüntüdeki piksel değerlerini karşılaştırmak olacaktır. Başka bir ifadeyle, bir görüntü histogramındaki piksellerin yoğunluk seviyelerine bağlı olarak kümeler ayırma işlemini gerçekleştirmektedir. Bu karşılaştırma işlemi (Eşitlik 1) sonucunda 0 ve 1'den oluşan ikili (*Binary*) görüntü elde edilir. Buna göre, görüntüdeki herhangi bir (i, j) pikseli için; $f(i, j) > T$ ise nesneye ait bir piksel, $f(i, j) \leq T$ ise arka plana ait bir piksel olacaktır.

$$f^T(i, j) = \begin{cases} 255, & \text{eğer } f(i, j) > T(i, j) \text{ ise} \\ 0, & \text{değilse} \end{cases} \quad (1)$$

Burada T değerinin doğru seçilmesi kritik önem taşımaktadır [8]. Eğer T değeri olması gereken daha fazla ya da az olursa görüntünün içerdiği anlamlı bilgi ciddi miktarda zarar görecektir. Bunun sonucu olarak, elde edilen ikili sonuç görüntüsü bir problemin çözümü için geliştirilen sistemin başarısını olumsuz etkileyecektir. Buna ilaveten, az sayıda görüntü için ideal eşik değeri deneme yoluyla bulunabilse de çok sayıda görüntü için bu zaman açısından mümkün olmayabilir. Bu nedenle, dijital görüntülerde eşik değerini otomatik olarak hesaplayan bir algoritmaya her zaman ihtiyaç duyulmuştur [9]. Uzun tarihinin ve geniş uygulamalarının yanı sıra, daha iyi binarizasyon algoritmaları geliştirmenin dışında, nitel ve nicel olarak değerlendirmesi ve bunların karşılaştırması aktif bir araştırma alanı olmaya devam etmektedir. Ayrıca görüntü analizinin geliştirilmesi açısından da son derece önemlidir.

2. GLOBAL EŞİKLEME YÖNTEMLERİ

Bugüne kadar gri seviyeli dijital görüntüler için farklı kategorilerde birçok otomatik global eşikleme yöntemi önerilmiştir. Bunlar başlıca kümeleme tabanlı, entropi tabanlı, şekil tabanlı, öznelik benzerliğine dayalı eşikleme algoritmaları olarak kullanılan bilgi türlerine göre kategorize edilmektedir [10]. Bu çalışmada ele alınan eşikleme yöntemlerinin matematiksel notasyonları ve çalışma prensipleri dört farklı alt başlık altında toplanmıştır. Eşikleme algoritmalarının matematiksel eşitliklerinden bahsederken notasyonları şu şekilde kullanacağız; $\forall g \in \{0, 1, \dots, G\}$ için burada G görüntüdeki maksimum gri seviye (parlaklık) değerini temsil etmektedir. Histogram $h(g)$, olasılık kütle fonksiyonu $p(g)$, kümülatif olasılık fonksiyonu $P(g) = \sum_{g=0}^G p(g)$, eşikleme değeri T ile gösterilmektedir. Ön plan (nesne) ve arka plan olasılık kütle fonksiyonları sırasıyla $p_f(g)$ ve $p_b(g)$ olarak ifade edilir ve bunlara ait olasılıklar aşağıdaki gibi hesaplanır;

$$P_b(T) = P_b = \sum_{g=0}^T p(g) \quad (2)$$

$$P_f(T) = P_f = \sum_{g=T+1}^G p(g) \quad (3)$$

Bu çalışmada, karşılaştırmak için kullandığımız bazı algoritmalar entropi tabanlıdır ve genel olarak Shannon'un entropisi üzerine inşa edilmiştir. Eşikleme değerine bağlı olarak, Shannon'un entropisinin ön plan ve arka plan hesaplamaları şu şekildedir;

$$H_b(T) = - \sum_{g=0}^T p_b(g) \log p_b(g) \quad (4)$$

$$H_f(T) = - \sum_{g=T+1}^G p_f(g) \log p_f(g) \quad (5)$$

Bu iki ifadenin toplamı ise; $H(T) = H_b(T) + H_f(T)$ şeklinde hesaplanır. Bulanık ölçümlerde ise ön plan ve arka plan fonksiyonları sırasıyla $m_f(g)$ ve $m_b(g)$ olarak ifade edilir ve aşağıda gösterildiği gibi hesaplanır;

$$\mu_b(T) = \sum_{g=0}^T gp(g) \quad (6)$$

$$\sigma_b^2(T) = \sum_{g=0}^T [g - \mu_b(T)]^2 p(g) \quad (7)$$

$$\mu_f(T) = \sum_{g=T+1}^G gp(g) \quad (8)$$

$$\sigma_f^2(T) = \sum_{g=T+1}^G [g - \mu_f(T)]^2 p(g) \quad (9)$$

2.1. Kümeleme Tabanlı Eşikleme

Kümeleme tabanlı otomatik eşikleme yöntemlerinden en iyi bilineni Otsu [11]'dir. Bu metot kullanılırken görüntünün arka plan ve ön plan olmak üzere iki renk sınıfından oluştuğu varsayımı yapılır. Bu iki sınıfı ayıran optimum eşik değerini (T) bulmak için sınıf içi varyans değeri minimum olacak şekilde hesaplanır;

$$\sigma_W^2(T) = p_f(T)\sigma_f^2(T) + p_b(T)\sigma_b^2(T) \quad (10)$$

Burada p_f ve p_b , T eşik değeri ile ayrılan iki sınıfın kütle olasılıklarını temsil eder. $\sigma_W^2(T)$ ise bu iki sınıfın varyansıdır. Otsu, sınıf içi varyansı en aza indirmenin, sınıflar arası varyansı maksimuma çıkarmakla aynı olduğunu gösterir. Bu nedenle daha basit olmasından dolayı kullanmak için çok daha iyi bir yaklaşımdır.

$$\sigma_B^2(T) = \sigma^2 - \sigma_W^2(T) \quad (11)$$

$$\sigma_B^2(T) = p_f(T)p_b(T)[\mu_f(T) - \mu_b(T)]^2 \quad (12)$$

Burada $\sigma_B^2(T)$ sınıflar arası varyansını, μ_f ve μ_b ise sınıf ortalamalarını temsil etmektedir. Doyle [12] tarafından önerilen P-tile (*Percentile*) algoritması gri seviye histogramı tabanlı en eski eşikleme yöntemlerinden biridir. Bir görüntüdeki nesnelerin arka plandan daha parlak olduğunu ve nesnelerin görüntü üzerinde sabit bir alan yüzdesini işgal ettiğini varsayar. Bu sabit alan yüzdesi de $K\%$ olarak bilinir. Eşik değeri (T), çoğunlukla gri seviyenin nesneye en az $K\%$ oranında eşleştirilmesine karşılık gelen gri seviye olarak tanımlanır. Bu oran otomatik işlemlerde genelde $K = 0.5$ olarak belirlenir. P-tile yönteminin algoritması Eşitlik 14'teki gibidir;

$$P = \sum_{g=0}^G h(g) \quad (13)$$

$$T = \underset{g}{\operatorname{argmin}} \left\{ \frac{1}{P} \sum_{g=0}^G p(g) \geq K \right\} \quad (14)$$

Burada P histogramdaki kümülatif olasılık toplam fonksiyonunu, T ise optimum eşik değerini temsil etmektedir. Simple Image Statistic (SIS), Kittler ve Illingworth [13] tarafından geliştirilen otomatik iki seviyeli bir eşik belirleme tekniğidir. Bu yöntemde, gri tonlamalı bir görüntüdeki gradyan büyüklüğüyle ağırlıklandırılmış piksel parlaklığına dayalı olarak optimum global eşik değeri Eşitlik 16'da gösterildiği gibi tahmin edilir.

$$e(i, j) = |\nabla p| = \max\{|l(i-1, j) - l(i+1, j)|, |l(i, j-1) - l(i, j+1)|\} \quad (15)$$

$$T_{opt} = \frac{\sum_{i=1}^m \sum_{j=1}^n |l(i, j) \times e(i, j)|}{\sum_{i=1}^m \sum_{j=1}^n |e(i, j)|} \quad (16)$$

Burada $l(i, j)$ ve $e(i, j)$ sırasıyla görüntüdeki parlaklığı ve gradyan büyüklüğünü temsil etmektedir. Piksel cinsinden görüntü boyutları ise m ve n olarak gösterilmektedir. Ridler ve Calvard [14], IsoData olarak adlandırılan otomatik olarak global eşik değerini belirleyen iteratif bir algoritma geliştirmişlerdir. Bu algoritmada ilk olarak, histogram T_0 gibi bir başlangıç eşik değeri belirlenerek iki kısma ayrılır. Yani T_0 histogramdaki piksel sayısı sıfırdan farklı en küçük parlaklık değeridir.

$$T_{opt} = \lim_{n \rightarrow \infty} \frac{\mu_f(T_n) + \mu_b(T_n)}{2} \quad (17)$$

$$\mu_f(T_n) = \sum_{g=0}^{T_n} gp(g) \quad (18)$$

$$\mu_b(T_n) = \sum_{g=T_n+1}^G gp(g) \quad (19)$$

Daha sonra T_0 eşik değeri referans alınarak, görüntü üzerindeki nesnelere ve arka plana ait gri seviyeli değerlerin ortalamaları sırasıyla μ_f ve μ_b olarak bulunur. Bir sonraki adımda ise μ_f ve μ_b değerlerinin aritmetik ortalaması alınarak yeni bir T_1 eşik değeri hesaplanır. Süreç, eşik değeri artık değişmeye kadar (T_n) yeni eşığe bağlı olarak tekrarlanır. Bir diğeri ise Mean [15] yöntemidir. Bu metot gri seviye dağılımının ortalamasını eşik olarak seçer. Bununla birlikte, diğer bazı yöntemler bunu ilk tahmin eşığı olarak kullanır.

$$T = \sum_{g=0}^G gp(g) \quad (20)$$

2.2. Entropi Tabanlı Eşikleme

Entropi kavramı ilk kez Shannon tarafından bilgisayar bilimlerinde sinyal işleme ve veri iletişimde kullanılmıştır. Enformasyon teorisinde bilginin ortalama miktarını ölçmek için de entropiden yararlanır. Görüntü analizinde entropi, rastgele bir değişkenin minimum tanımlayıcı karmaşıklığını ölçmek için kullanılır. Bu yönü ile görüntü işleme alanında da oldukça tercih edilen bir kavramdır. Kapur ve ark. [16], MaxEntropy olarak bilinen algoritmasında, görüntü histogramındaki gri düzeylerin dağılımının entropisini hesaplayabilmek için Shannon'un konseptini kullanmıştır. Görüntüdeki nesnelere ve arka plan iki farklı sinyal kaynağı olarak düşünülürse, bu iki sınıfa ait entropilerinin toplamı maksimum seviyeye ulaştığı durumda optimum eşik değeri bulunmuş olur.

$$T_{opt} = argmax[H_f(T) + H_b(T)] \quad (21)$$

$$H_f(T) = - \sum_{g=0}^T \frac{p(g)}{p(T)} \log_e \frac{p(g)}{p(T)} \quad (22)$$

$$H_b(T) = - \sum_{g=T+1}^G \frac{p(g)}{p(T)} \log_e \frac{p(g)}{p(T)} \quad (23)$$

Sahoo ve ark. [17], Renyi entropisini kullanarak görüntü histogramında T_1 , T_2 ve T_3 olmak üzere üç farklı eşik değeri bulunur. Bu eşik değerleri ρ parametresinin $\rho > 1$, $0 < \rho < 1$ ve $\rho = 1$ durumları esas alınarak Eşitlik 24 ve 25'te gösterildiği gibi hesaplanır.

$$H_f^\rho = \frac{1}{1-\rho} \ln \left\{ \sum_{g=0}^T \left[\frac{p(g)}{p(T)} \right]^\rho \right\} \quad (24)$$

$$H_b^\rho = \frac{1}{1-\rho} \ln \left\{ \sum_{g=T+1}^G \left[\frac{p(g)}{p(T)} \right]^\rho \right\} \quad (25)$$

Optimum eşik değeri ise nesnelere ve arka plana ait gri seviyelerin Renyi entropi toplamalarını maksimize edilerek Eşitlik 26'da gösterildiği gibi hesaplanır.

$$T_{opt} = T_{[1]} \left[P_{T_{[1]}} + \frac{1}{4} wB_1 \right] + T_{[2]} \frac{1}{4} wB_2 + T_{[3]} \left[1 - P_{T_{[3]}} + \frac{1}{4} wB_3 \right] \quad (26)$$

$$P[T_{[k]}] = \sum_{g=0}^{T_{[k]}} p(g), \forall k \in \{1,2,3\} \quad (27)$$

$$x = |T_{[1]} - T_{[2]}|, y = |T_{[1]} - T_{[3]}| \quad (28)$$

$$B_1, B_2, B_3 = \begin{cases} (1,2,1) & \text{if } x \leq 5 \text{ and } y \leq 5 \text{ or } x > 5 \text{ and } y > 5 \\ (0,1,3) & \text{if } x \leq 5 \text{ and } y > 5 \\ (3,1,0) & \text{if } x > 5 \text{ and } y \leq 5 \end{cases} \quad (29)$$

Li ve ark. [18, 19], ikili ve orijinal görüntü arasındaki çapraz-entropinin minimize edilebilmesi için kullanılan yinelemeli bir yöntem önermişlerdir. Bu, görüntüler arasındaki veri tutarlılığının bir ölçüsü olarak yorumlanır ve optimal eşiklemeyi Kullback-Leibler mesafesinin en aza indirilmesi olarak formüle eder. Kullback-Leibler ölçüsü ile gözlemlenen ve yeniden oluşturulan görüntülerin, ön plan ve arka planları aynı ortalama yoğunluğa sahip olduğu kısıtlar altında minimize eder.

$$T_{opt} = argmin \left[\sum_{g=0}^T gp(g) \log \frac{g}{m_f(T)} + \sum_{g=T+1}^G gp(g) \log \frac{g}{m_b(T)} \right] \quad (30)$$

$$\text{Where } \square \sum_{g \leq T} g = \sum_{g \leq T} m_f(T) \square \text{ and } \square \sum_{g \geq T} g = \sum_{g \geq T} m_b(T) \square \quad (31)$$

Shanbhag [20] tarafından önerilen yöntem, Kapur ve ark. [16] tarafından önerilen maksimum entropi eşikleme tekniğinin farklı bir sürümüdür. Shanbhag eşikleme bulanık üyeleri (*fuzzy memberships*), görüntüdeki gri seviyelerin nesneye veya arka plana ne kadar güçlü bir şekilde ait olduğunun bir göstergesi olarak görür. Bu yöntemde, bir görüntü iki bulanık kümeye karşılık gelen iki farklı sınıfa ayrılır: μ_f histogramdaki 0'dan T 'ye kadar olan gri seviyeleri, μ_b ise $T + 1$ 'den G 'ye kadar olan gri seviyeleri temsil etmektedir. Üyelik katsayıları, ilgili gri seviyenin bir sınıfa atanmasındaki belirsizlik olarak ölçülür. Açıkçası, yalnızca minimum ve maksimum olası gri düzeylerine sahip pikseller, maksimum üyelik katsayısına göre μ_f veya μ_b 'ye atanacaktır. Bu da yüksek değerlikli gri seviyelerin herhangi bir belirsizlik olmadan kendi sınıflarına nasıl atanacağını açıklar. Bununla birlikte, T ve $T + 1$ eşik değerleri arasında farazi bir T' olduğu varsayılır. Bu nedenle, T' gri değerine sahip piksel değerleri 0.5'lik üyelik katsayısına sahip olacaktır. Bir sınıfa göre herhangi bir gri seviyenin üyelik katsayısı, bu gri seviyeye sahip olan piksellerin bulunma olasılığı ile de artar.

$$\mu_f(T - i) = 0.5 + \frac{P(T)+\dots+P(T-1-i)+P(T-i)}{2P(T)} \quad (32)$$

$$\mu_b(T + i) = 0.5 + \frac{P(T+1)+\dots+P(T-1+i)+P(T-i)}{2(1-P(T))} \quad (33)$$

Sonuç olarak, bir sınıf içindeki eşikten daha büyük bir piksel yoğunluğu daha yüksek üyelik olarak belirlenir. Böylece, arka plan ve nesnelerin entropileri hesaplanır ve optimum eşik değeri, iki entropi arasındaki farkı minimize eden T_{opt} olarak Eşitlik 34'teki gibi belirlenir.

$$T_{opt} = argmin\{H_f(T) - H_b(T)\} \quad (34)$$

$$H_f(T) = - \sum_{g=0}^T \frac{P(g)}{P(T)} \log[\mu_f(g)] \quad (35)$$

$$H_b(T) = - \sum_{g=T+1}^G \frac{P(g)}{1-P(T)} \log[\mu_b(g)] \quad (36)$$

Yen ve ark. [21], Renyi entropisindeki güç parametresini $\rho = 2$ olarak belirleyerek, optimum eşik değerini maksimize eden bir entropik korelasyon yöntemi önermişlerdir. Buna göre görüntüdeki optimal eşik değeri Eşitlik 37'deki gibi hesaplanır.

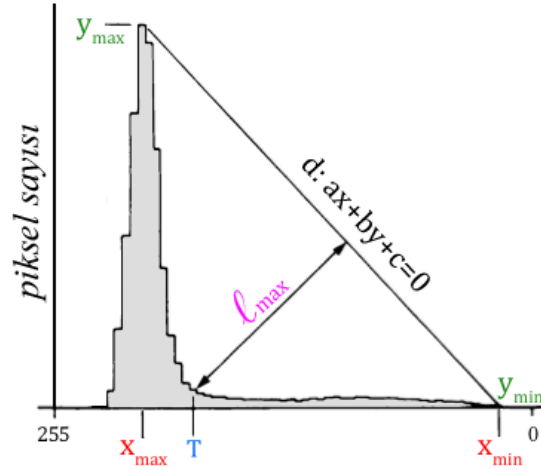
$$T_{opt} = argmax\{C_b(T) + C_f(T)\} \quad (37)$$

$$C_b(T) = - \log \left\{ \sum_{g=0}^T \left[\frac{p(g)}{p(T)} \right]^2 \right\} \quad (38)$$

$$C_f(T) = - \log \left\{ \sum_{g=T+1}^G \left[\frac{p(g)}{1-p(T)} \right]^2 \right\} \quad (39)$$

2.3. Şekil Tabanlı Eşikleme

Bu yöntem kategorisindeki algoritmalar, görüntü histogramı üzerinde geometrik şekil benzerliği, eğri analizi, referans tepe noktaları, vadiler vb. biçimde şekil özelliklerine göre eşik değeri seçerler. Bunlardan en çok bilineni Zack'in Triangle [22] algoritmasıdır. Bu yöntemde, gri seviyeli bir görüntü histogramında maksimum tepe değeri y_{max} ve minimum tepe değeri y_{min} bulunur. Aynı zamanda bu tepe değerlerine karşılık gelen x_{min} ve x_{max} gri seviye değerleri de tespit edilmiş olur. Daha sonra bu noktaların arası Şekil 1'de gösterildiği gibi bir çizgi ile birleştirilerek $d: ax + by + c = 0$ doğrusu elde edilir.



Şekil 1. Zack'in üçgen yöntemi.

$$x_{min} = argmin_g \{ \sum_{g=0}^G p(g) > 0 \}, y_{min} = h(x_{min}) \quad (40)$$

$$x_{max} = argmax_g \{ \sum_{g=0}^G p(g) > 0 \}, y_{max} = h(x_{max}) \quad (41)$$

Ancak burada bilinmesi gereken bir şey daha vardır. Histogramda x_{min} değeri sağ tarafta olabileceği gibi sol tarafta da olabilir. Bu durumda x_{min} ile x_{max} değerleri yer değiştirilir. Ayrıca tüm gri seviyeler eşit durumda $x_{min} = x_{max}$ olursa optimum T değeri x_{min} veya x_{max} 'tan biri olarak belirlenir. Daha sonra bu bilgileri kullanarak, iki noktası bilinen d doğrusunun denklemini aşağıdaki gibi elde edilir.

$$d: (x - x_{max})(y_{max} - y_{min}) - (y - y_{max})(x_{max} - x_{min}) \quad (42)$$

Bu eşitliği $d: ax + by + c = 0$ olduğunu varsayarsak, optimum eşik değeri aşağıdaki formülde gösterildiği gibi hesaplanır. Yani l uzunluğunun maksimum olduğu (l_{max}) yerdeki x_n değeridir.

$$T_{opt} = \underset{n}{argmax} \left\{ n | n \in \{x_{min}, \dots, x_{max}\}, \frac{|an+bh(n)+c|}{\sqrt{a^2+b^2}} \right\} \quad (43)$$

Bu teknik, histogramda nesneye ait piksellerin zayıf bir tepe meydana getirdiği durumlarda etkilidir. Prewit ve ark. [23], kan hücrelerinin analizi için yaptıkları çalışmada periferik kan yayma görüntülerinin gri seviyeli histogramı üzerinden lökosit hücrelerinin nükleus ve sitoplazmalarını segmente etmek istemişlerdir. Bunun için Intermodes olarak bilinen çift modlu (*bimodal*) bir eşikleme yöntemi önermişlerdir. Bu yöntem, histogramın iki modlu bir dağılımı olduğunu varsayar ve iki yerel maksimumu lokalize etmeye çalışır. Bu yerel maksimumlar bulunduğu, yoğunlukları arasındaki ortalama optimum eşik değeri olarak belirlenir. Geniş ve düz bir vadiye veya oldukça düzensiz yapıda zirvelere sahip olan histogramlar bu yöntem için uygun değildir.

2.4. Öznitelik Benzerliğine Dayalı Eşikleme

Bu kategorideki algoritmalar, orijinal görüntü ile ikili görüntü arasında bazı özellik kalitesi veya benzerlik ölçüsüne dayalı eşik değerini belirler. Bu nitelikler, kenar eşleştirme, şekil kompaktlığı, moment, bağlantı, doku veya segmente edilmiş nesnelerin kararlılığı olarak söylenebilir. Tsai [24], Gri seviyeli bir görüntüyü, ideal bir ikili görüntünün bulanık sürümü olarak görür. Optimum eşikleme, ilk üç gri seviye momentinin, ikili görüntünün ilk üç momentine denk gelecek şekilde Eşitlik 46'daki gibi oluşturulur. Gri seviyeli momentler m_k olarak, binary görüntü momentleri ise b_k olarak tanımlanmıştır.

$$m_k = \sum_{g=0}^G p(g) g^k \quad (44)$$

$$b_k = P_f m_f^k + P_b m_b^k \quad (45)$$

$$T_{opt} = \underset{t}{arg e qual} [m_1 = b_1(T), m_2 = b_2(T), m_3 = b_3(T)] \quad (46)$$



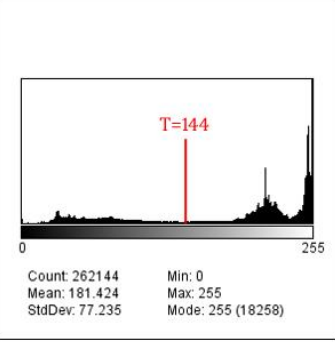


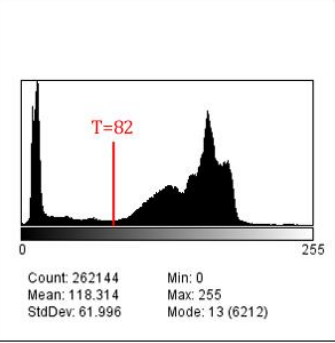


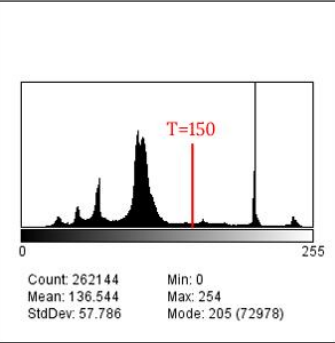
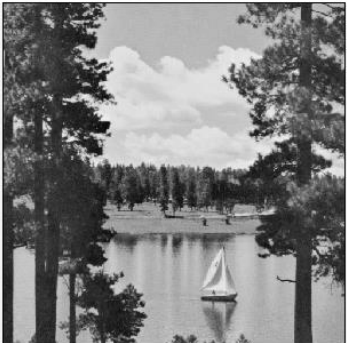
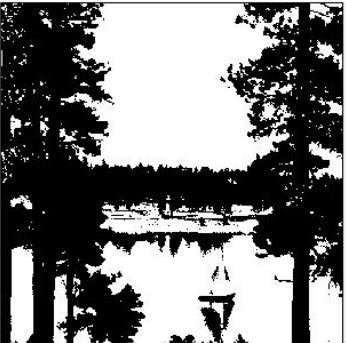
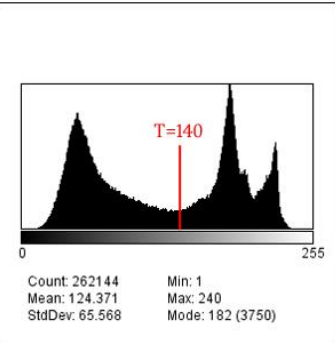

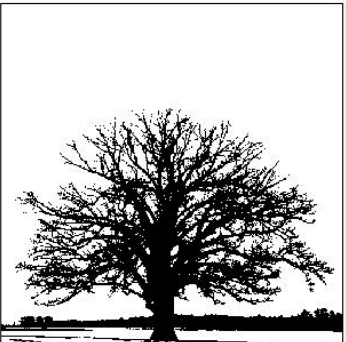
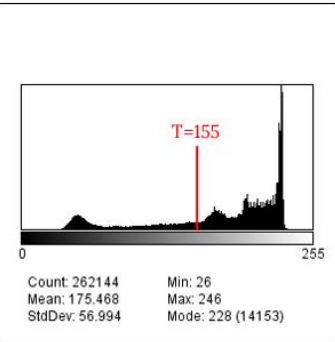
Huang ve ark. [25], gri ölçekli görüntülerin histogram bilgilerini kullanarak, bulanık entropi-tabanlı (*fuzzy entropy-based*) bir eşikleme yöntemi geliştirmişlerdir. Bu yöntem, gri ölçekli görüntü ile ikili görüntü arasındaki mesafeyi ölçerek bir bulanıklık indeksi oluşturur. Görüntü $m_f(I)$ dizisi olarak temsil edilir ve burada $0 \leq m_f(I) \leq 1$ olarak, ön plana ait olan bulanık ölçüyü temsil eder. Her bir görüntü pikseli için bulanık üyelik değeri göz önüne alındığında, Shannon'un veya Yager'in entropi fonksiyonuyla görüntünün tümü için bir bulanıklık indeksi elde edilebilir. Optimal eşik, sınıf (ön ve arka plan) ortalama (*mean*) $m_f(T)$, $m_b(T)$ ve üyelik fonksiyonları $\mu_f[I(i, j), T]$, $\mu_b[I(i, j), T]$ açısından tanımlanan bulanıklık indeksi minimize ederek, Eşitlik 47'de gösterildiği gibi hesaplanır [10, 26].

$$T_{opt} = \underset{t}{argmin} \left\{ -\frac{1}{N^2 \log 2} \sum_{g=0}^G \left(\left[\mu_f(g, T) \log(\mu_f(g, T)) \right] + \left[[1 - \mu_f(g, T)] \log[1 - \mu_f(g, T)] p(g) \right] \right) \right\} \quad (47)$$

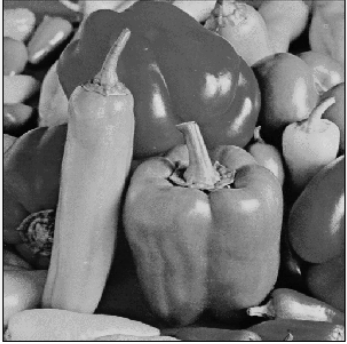

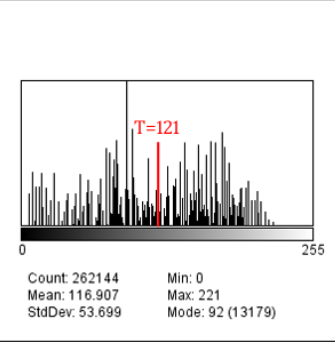
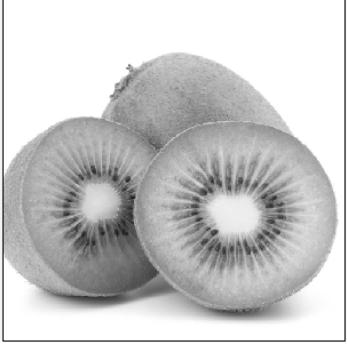
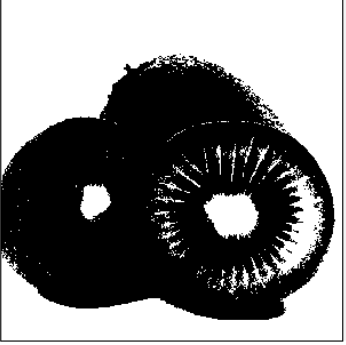
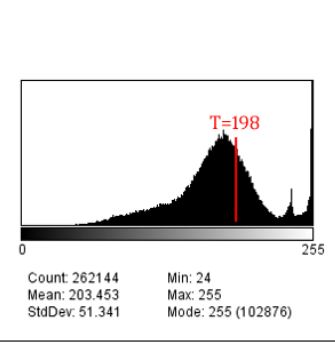


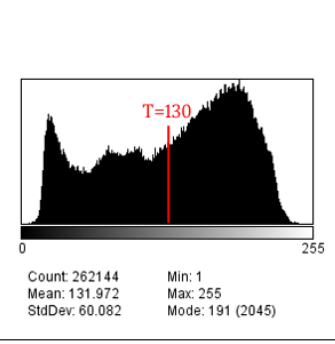
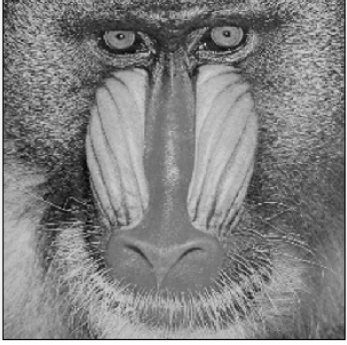

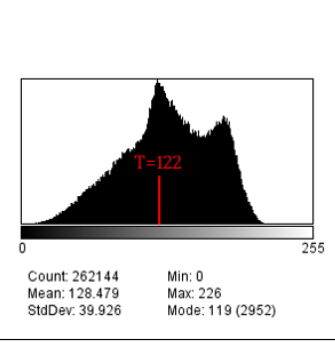
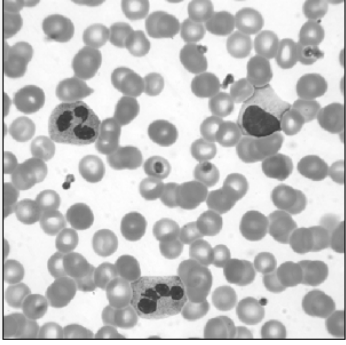
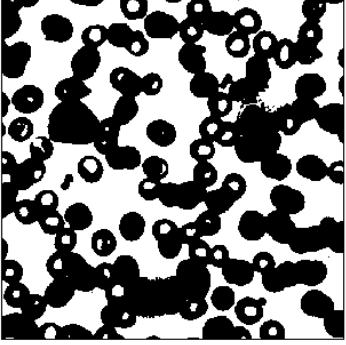
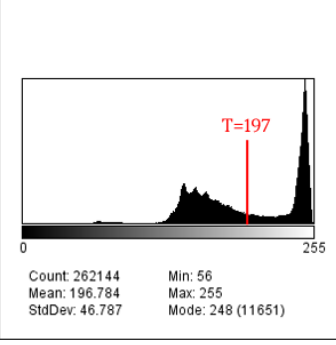
$$\mu_f[I(i, j), T] = \frac{G}{G + |I(i, j) - m_f(T)|} \quad (48)$$

3. DENEYSEL ÇALIŞMALAR

Deneysel çalışmalarda her birinde beş görüntü bulunan üç bölüm halinde veri seti (Şekil 2, Şekil 3 ve Şekil 4) hazırlanmıştır. Bunlar görüntü işleme çalışmalarında sıklıkla kullanılan (iyi bilinen) görüntüler, biyolojik, coğrafi, kültürel ve diğer çeşitli türlerde olan görüntülerdir. Veri setleri yalnızca fiziksel nedenlerden dolayı (sayfa boyutu ve görüntü sayısı) gruplandırılmıştır. Görüntüler 512×512 piksel boyutlarında ve gri ölçeklidir (8-bit). Deneysel çalışmada kullanılan tüm görüntüler için dört farklı uzman tarafından uygun bir eşik değeri belirlenmiştir. Bunun sebebi yapılan çalışmayı kişisel önyargıdan uzak tutmaktır. Daha sonra uzman kişiler tarafından belirlenen her bir görüntü için eşik değerlerin ortalaması alınarak hesaplanan referans eşik değerleri (T) olarak belirtilmiştir. Buna göre giriş görüntülerinin T eşik değerine göre ikili görüntüleri elde edilmiştir. Tüm görüntü seti için uzmanlar arasındaki görüş farklılığının ortalama standart sapma değeri 3.87'dir. Görüntü setlerinin verildiği her bir tabloda giriş görüntüsü, T eşik değerine göre oluşturulmuş ikili referans (ground-truth) görüntüsü (GTI) ve giriş görüntüsüne ait histogram grafiği ile buna ait bazı istatistiksel değerler verilmiştir.

ID	Giriş Görüntüsü	Referans Görüntü	Görüntü Histogramı
A1			 <p>Count: 262144 Mean: 181.424 StdDev: 77.235</p> <p>Min: 0 Max: 255 Mode: 255 (18258)</p>
A2			 <p>Count: 262144 Mean: 118.314 StdDev: 61.996</p> <p>Min: 0 Max: 255 Mode: 13 (6212)</p>
A3			 <p>Count: 262144 Mean: 136.544 StdDev: 57.786</p> <p>Min: 0 Max: 254 Mode: 205 (72978)</p>
A4			 <p>Count: 262144 Mean: 124.371 StdDev: 65.568</p> <p>Min: 1 Max: 240 Mode: 182 (3750)</p>
A5			 <p>Count: 262144 Mean: 175.468 StdDev: 56.994</p> <p>Min: 26 Max: 246 Mode: 228 (14153)</p>

Şekil 2. Veri Seti (Bölüm A)

ID	Giriş Görüntüsü	Referans Görüntü	Görüntü Histogramı
B1			 <p>Count: 262144 Min: 0 Mean: 116.907 Max: 221 StdDev: 53.699 Mode: 92 (13179)</p>
B2			 <p>Count: 262144 Min: 24 Mean: 203.453 Max: 255 StdDev: 51.341 Mode: 255 (102876)</p>
B3			 <p>Count: 262144 Min: 1 Mean: 131.972 Max: 255 StdDev: 60.082 Mode: 191 (2045)</p>
B4			 <p>Count: 262144 Min: 0 Mean: 128.479 Max: 226 StdDev: 39.926 Mode: 119 (2952)</p>
B5			 <p>Count: 262144 Min: 56 Mean: 196.784 Max: 255 StdDev: 46.787 Mode: 248 (11651)</p>

Şekil 3. Veri Seti (Bölüm B)

ID	Giriş Görüntüsü	Referans Görüntü	Görüntü Histogramı
C1			
C2			
C3			
C4			
C5			

Şekil 4. Veri Seti (Bölüm C)

Deneyisel çalışmalarda, görüntü ikileştirilmesi için 14 farklı global eşikleme algoritması test edilmiştir. Bu algoritmalar; Huang (HG) [25], Intermodos (IM) [23], IsoData (IS) [14], Li (LI) [18, 19], Max entropy (ME) [16], Mean (MN) [15], Moments (MT) [24], Otsu (OT) [11], Percentile (PT) [12], Renyi entropy (RE) [17], Shanbhag (SH) [20], Simple Image Statistics (SI) [13], Zack's triangle (ZT) [22] and Yen (YN) [21] olarak tablo ve grafiklerdeki gösterimleri için kısaltılmıştır. Ayrıca deneylerde referans görüntüsü (Ground-truth) için de (GTI) kısaltması kullanılmıştır. Veri setindeki tüm görüntüler için her bir algoritma tarafından hesaplanan optimum eşik değerleri Tablo 1'de gösterilmektedir.

Tablo 1. Veri setindeki görüntülerin algoritmalara göre optimal ve referans eşik değerleri.

#	GTI	HG	IM	IS	LI	ME	MN	MT	OT	PT	RE	SH	SI	ZT	YN
A1	144	141	128	148	128	169	181	157	149	214	173	74	133	235	188
A2	82	58	88	88	63	195	118	112	88	142	191	133	112	23	198
A3	150	165	155	148	140	95	136	114	148	111	95	38	124	201	96
A4	140	114	116	124	110	123	124	126	125	123	123	119	112	163	123
A5	155	180	137	142	127	151	175	153	143	197	155	111	135	221	160
B1	121	135	126	117	106	120	116	106	117	117	123	129	115	96	128
B2	198	237	214	205	201	131	203	181	206	199	138	36	160	252	139
B3	130	130	108	120	105	123	131	124	121	143	123	120	126	113	124
B4	122	141	148	126	120	105	128	122	128	129	105	128	123	98	105
B5	197	211	195	198	194	126	196	178	199	193	125	165	188	232	125
C1	175	173	178	182	176	218	218	181	182	234	215	126	192	216	220
C2	125	39	106	103	73	145	69	110	104	24	110	15	124	27	102
C3	194	214	204	191	188	118	192	172	192	201	118	160	168	225	118
C4	140	158	133	149	135	168	202	162	150	211	167	63	167	185	168
C5	161	231	219	205	200	119	226	184	206	254	234	7	167	250	249

Her bir algoritma için eşikleme sonucunda elde edilen ikili görüntülerin benzerliklerini hesaplamada Eşitlik 49'da verilen Jaccard Index (Jaccard benzerlik katsayısı) yönteminden faydalanılmıştır. Bu yöntemle göre işlemin sonucunda hesaplanan değer 0 ile 1 arasındadır. İşlemin sonucu 1'e ne kadar yakınsa, iki görüntü birbirine o kadar benzerdir.

$$JIX = \frac{(\sum_{i=0}^m \sum_{j=0}^n f_G(i,j) \wedge f_T(i,j))}{(\sum_{i=0}^m \sum_{j=0}^n f_G(i,j) \vee f_T(i,j))} \quad (49)$$

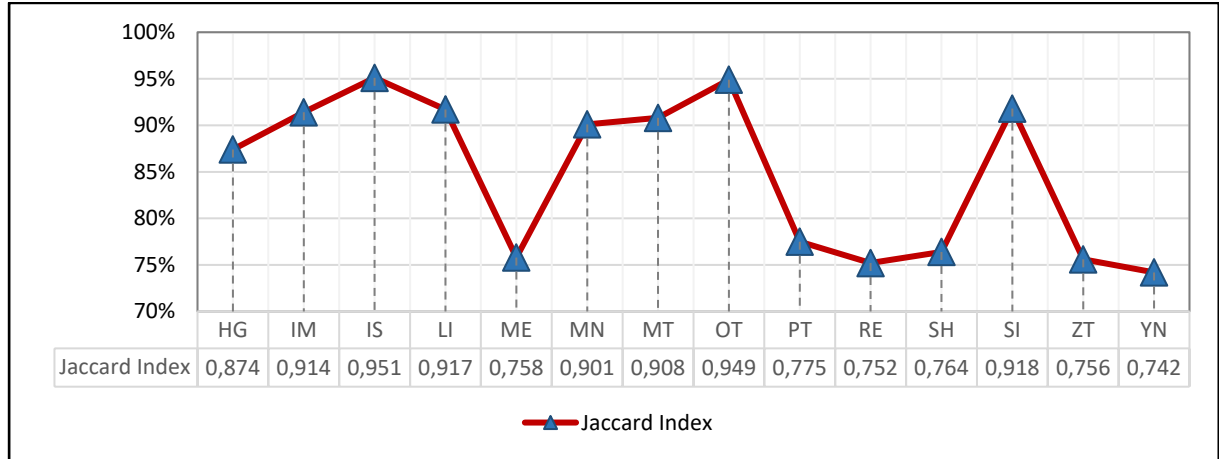
Burada m ve n görüntünün boyutlarını, f_G referans görüntüsünü ve f_T ise eşikleme sonucunda elde edilen ikili çıkış görüntüsünü temsil etmektedir. Tablo 2'de görüntü setindeki tüm görüntüler için her bir eşikleme algoritmasına göre JIX benzerlikleri verilmiştir. Algoritmaların benzerlik değerlendirmesinde, uzman görüşüne göre eşikleme (GTI) yapılan ikili referans görüntüler esas alınmıştır.

Tablo 2. Jaccard Index yöntemine göre algoritmalar tarafından üretilen ikili görüntülerin benzerlik yüzdeleri.

#	HG	IM	IS	LI	ME	MN	MT	OT	PT	RE	SH	SI	ZT	YN
A1	99,4	97,4	99,5	97,4	96,0	93,5	98,0	99,4	72,2	95,2	85,6	98,2	46,1	91,9
A2	96,9	99,4	99,4	97,6	1,8	87,6	91,4	99,4	68,1	2,3	75,2	91,4	91,6	1,6
A3	95,2	98,8	99,2	96,9	49,2	96,0	82,7	99,2	77,4	49,2	40,3	92,3	87,0	49,5
A4	89,8	90,6	93,6	88,2	93,2	93,6	94,4	94,0	93,2	93,2	91,8	89,0	88,0	93,2
A5	82,2	93,6	95,0	91,1	98,1	86,3	98,9	95,3	68,8	99,6	87,8	93,1	36,3	98,4
B1	88,3	97,7	96,5	87,6	98,7	96,1	87,6	96,5	96,5	98,5	93,3	95,3	80,0	96,0
B2	84,4	90,1	94,8	98,1	55,7	96,3	80,1	94,1	100	56,7	50,7	63,4	80,3	56,9
B3	99,2	86,3	92,5	84,9	94,3	100	95,0	93,1	89,9	94,3	92,5	96,3	88,7	95,0
B4	70,2	60,5	94,4	94,6	77,6	90,9	98,2	90,9	89,2	77,6	90,9	100	73,2	77,6
B5	92,8	98,1	100	97,4	50,1	98,7	85,1	99,4	96,7	50,0	73,7	93,3	82,5	50,0
C1	99,8	99,8	99,6	100	96,4	96,4	99,7	99,6	63,3	96,9	92,4	98,9	96,8	96,0
C2	45,4	82,6	80,3	58,8	82,6	56,4	85,8	81,1	20,3	85,8	19,9	98,1	42,3	79,5
C3	91,0	97,4	99,1	98,3	54,0	99,3	74,7	99,3	98,2	54,0	67,8	71,4	71,4	54,0
C4	98,9	99,5	99,5	99,6	97,9	82,7	98,5	99,4	56,8	98,0	96,0	98,0	94,9	97,9
C5	77,4	79,5	83,3	85,0	91,4	78,1	91,5	82,9	72,1	77,1	88,1	98,2	75,6	75,8
Mean	87,4	91,4	95,1	91,7	75,8	90,1	90,8	94,9	77,5	75,2	76,4	91,8	75,6	74,2

Tablonun son satırında ise veri setindeki tüm görüntülerin ortalama benzerlik oranı hesaplanmıştır. Buna ek olarak, tablodaki her bir görüntü için en iyi benzerlik oranına sahip metodlar kırmızı ile renklendirilmiştir. Ortalama benzerlik oranları mukayese edildiğinde, en yüksek skor yaklaşık %95 ile IsoData ve Otsu algoritmalarına ait olduğu görülmektedir. Eşikleme algoritmalarının yedi tanesi referans görüntüler ile %90'ın üzerinde bir benzerliğe

sahiptir. Yen'in yöntemi ise %74,2'lik skorla benzerlikte en son sırada yer almaktadır. Şekil 5'te eşikleme algoritmalarının GTI'ya göre ortalama benzerlik grafiği gösterilmektedir.



Şekil 5. Jaccard Index yöntemine göre algoritmaların GTI ile benzerlikleri.

4. SONUÇLAR

Bu çalışmada gri-ölçekli görüntülerden oluşan bir veri seti için optimal eşik değerlerinin belirlenmesinde global eşikleme algoritmaları kullanılmıştır. Bu algoritmalar, herhangi bir parametreye ihtiyaç duymaksızın otonom olarak işlemleri gerçekleştirebilmektedir. Deneysel çalışmalarda kullanılan görüntü örneklerinin referans eşik değerleri hesaplanırken, kişisel önyargılara takılmamak için dört farklı uzman tarafından eşik değeri belirlenmesi istenmiştir. Bunun sonucunda da her bir örnek görüntü için uzmanların belirlediği eşik değerlerinin ortalaması alınarak, ikili referans görüntüleri oluşturulmuştur. Veri setindeki tüm görüntüler için uzman görüş farklılığının ortalama standart sapma değeri 3,87 olduğu ve görüntüler arasında gözle ayırt edilebilir bir fark olmadığı görülmüştür. Test sonuçlarında Jaccard Index'e göre IsoData ve Otsu algoritmalarının ortalamada en iyi benzerlik oranına ve en iyi ikili sınıflandırma başarısına sahip olduğu görülmüştür. Elbette edilen bulgular, diğer algoritmaların daha düşük benzerlik oranına sahip olduğu için kötü olduğu anlamına gelmemelidir. Her biri spesifik çözümler için tercih edilebilecek potansiyele sahip yöntemlerdir.

KAYNAKÇA

- [1] Kotte, S., Rajesh Kumar, P., & Injeti, S. K., "An efficient approach for optimal multilevel thresholding selection for gray scale images based on improved differential search algorithm", Ain Shams Engineering Journal, vol. 9, no. 4, pp. 1043-1067, 2018.
- [2] Wang, Z., Wang, E., & Zhu, Y., "Image segmentation evaluation: a survey of methods", Artificial Intelligence Review., 2020.
- [3] Ramola, A., Shakya, A.K., & Pham, D.V., "Study of statistical methods for texture analysis and their modern evolutions", Engineering Reports, vol. 2, no. 4, pp. 1-24, 2020.
- [4] Aqeel, E. F., "The Use of Threshold Technique in image segmentation", Journal of the College of Basic Education, vol. 21, no. 89, pp. 1-12, 2015.
- [5] Zaitoun, N.M., & Aqel, M.J., "Survey on Image Segmentation Techniques", Procedia Computer Science, vol. 65, pp. 797-806, 2015.
- [6] Singh, T.R., Roy, S., Singh, O.I., Sinam, T., & Singh, Kh.M., "A New Local Adaptive Thresholding Technique in Binarization", International Journal of Computer Science Issues, vol. 8, no. 2, pp.271-277, 2011.
- [7] Ceylan, R., & Koyuncu, H., "ScPSO-Based Multithresholding Modalities for Suspicious Region Detection on Mammograms", Soft Computing Based Medical Image Analysis, Academic Press, pp. 109-135, 2018.
- [8] Rosin, P., "Thresholding for change detection". Sixth International Conference on Computer Vision (IEEE Cat. No.98CH36271), pp. 274-279, 1998.
- [9] Ekielski, A., "An algorithm for determination of threshold value in extruded products by the method of maximum increments: modification of Otsu method", Annals of Warsaw University of Life Sciences-SGGW, Agriculture no. 62, pp. 71-79, (2013).
- [10] Sezgin, M. & Sankur, B., "Survey over Image Thresholding Techniques and Quantitative Performance Evaluation", Journal of Electronic Imaging, vol. 13, no. 1, pp. 146-165, 2004.

- [11] Otsu, N., "A threshold selection method from gray-level histograms", *IEEE Trans. Sys., Man., Cyber.*, vol. 9, pp. 62-66, 1979.
- [12] Doyle, W., "Operation useful for similarity-invariant pattern recognition", *Journal of the Association for Computing Machinery* vol. 9, pp. 259-267, 1962.
- [13] Kittler, J., Illingworth, J. and Foglein, J., "Threshold selection based in a simple image statistic", *Computer Vision, Graphics and Image Processing*, vol. 30, pp. 125-147, 1985.
- [14] Ridler, T. W. & Calvard, S., "Picture thresholding using an iterative selection method", *IEEE Transactions on Systems, Man and Cybernetics*, vol. 8, pp. 630-632, 1978.
- [15] Glasbey, C. A., "An analysis of histogram-based thresholding algorithms", *CVGIP: Graphical Models and Image Processing*, vol. 55, pp. 532-537, 1993.
- [16] Kapur, J. N., Sahoo, P. K. & Wong, A. C. K., "A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram", *Graphical Models and Image Processing*, vol. 29, no. 3, pp. 273-285, 1985.
- [17] Sahoo, P., Wilkins, C. & Yeager, J., "Threshold selection using Renyi's entropy", *Pattern Recognition*, vol. 30, no. 1, pp. 71-84, 1997.
- [18] Li, C. H. & Lee, C. K., "Minimum Cross Entropy Thresholding", *Pattern Recognition*, vol. 26, no. 4, pp. 617-625, 1993.
- [19] Li, C. H. & Tam, P. K. S., "An Iterative Algorithm for Minimum Cross Entropy Thresholding", *Pattern Recognition Letters*, vol. 18, no.8, pp. 771-776, 1998.
- [20] Shanbhag, Abhijit G., "Utilization of information measure as a means of image thresholding", *Graph. Models Image Process. (Academic Press, Inc.)*, vol. 56, no. 5, pp. 414-419, 1994.
- [21] Yen J. C., Chang F. J., Chang S., "A New Criterion for Automatic Multilevel Thresholding", *IEEE Trans. on Image Processing*, vol. 4, no. 3, pp. 370-378, 1995.
- [22] Zack, G. W., Rogers, W. E., Latt, S. A., "Automatic measurement of sister chromatid exchange frequency", *J. Histochem. Cytochem*, vol. 25, no. 7, pp. 741-53, 1977.
- [23] Prewitt, J. M. S. & Mendelsohn, M. L., "The analysis of cell images", *Annals of the New York Academy of Sciences*, vol. 128, pp. 1035-1053, 1966.
- [24] Tsai, W., "Moment-preserving thresholding: a new approach", *Computer Vision, Graphics, and Image Processing*, vol. 29, pp. 377-393, 1985.
- [25] Huang, L-K. & Wang, M-J. J., "Image thresholding by minimizing the measure of fuzziness", *Pattern Recognition*, vol. 28, no. 1, pp. 41-51, 1995.
- [26] Stelios, K., Michail, K., & Vassilios, C., "An Empirical Method for Threshold Selection", *International Journal of Signal Processing, Image Processing and Pattern Recognition*, vol. 5, no. 2, pp. 101-114, 2012.