

Eşikleme Tekniklerinin Renk Uzayı Tabanlı Kümeleme Yönteminin Başarısına Etkisi

Mahmut KILIÇASLAN^{1*}, Ufuk TANYERİ¹, Mürsel Ozan İNCETAŞ², Burcu YAKIŞIR GİRĞİN³, Recep DEMİRCİ⁴

¹Bilgisayar Teknolojisi Bölümü, Nallıhan Meslek Yüksekokulu, Ankara Üniversitesi, Ankara/Türkiye

²Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Bülent Ecevit Üniversitesi, Zonguldak/Türkiye

³Elektronik ve Otomasyon Bölümü, Nallıhan Meslek Yüksekokulu, Ankara Üniversitesi, Ankara/Türkiye

⁴Bilgisayar Mühendisliği Bölümü, Teknolojisi Fakültesi, Gazi Üniversitesi, Ankara/Türkiye

* (m.kilicaslan @ankara.edu.tr) İlgili yazarın e-postası

Özet – Eşikleme yöntemleri kenar belirleme, bölütleme ve kümeleme yaklaşımlarında sıklıkla kullanılmaktadır. Söz konusu teknikler yardımıyla renk kanallarından çeşitli sayıda kümeler elde edilebilir. Ancak, hangi yaklaşımın daha başarılı olduğu konusu belirsizliğini korumaktadır. Bu çalışmada, çok sık tercih edilen Histogramın Ağırlık Merkezi (HAM), OTSU ve KAPUR eşikleme algoritmaları kullanılarak yapılan renk uzayı tabanlı kümeleme sonuçları, 100 görüntüden oluşan Weizmann tek nesneli bölütleme veritabanı yardımıyla test edilmiş ve farklı eşikleme yöntemi ile elde edilen renk kümelerine ait bölütleme sonuçları F-Skor olarak kaydedilmiştir. Böylece, kümeleme işlemi için sıklıkla kullanılan eşikleme yöntemlerinin başarısı nicemsel olarak belirlenmiş ve birbirleriyle karşılaştırılmıştır.

Anahtar Kelimeler – Eşikleme, Renk Uzayı, Kümeleme

I. GİRİŞ

Görüntü bölütleme olarak bilinen kavram, bilgisayar aracılığıyla kullanılan imgelerde, dijital bir görseli birden çok piksel kümelerine (süper piksel) bölme işlemi olarak açıklanır. Amaç, bir görüntünün sunumunu basitleştirmek veya onu daha anlamlı ve analiz edilmesi mümkün hale getirmektir [1]. Söz konusu işlem, genellikle nesnelere ve sınırları (çizgiler, eğriler vb.) tespit etmede kullanılmaktadır. Başka bir deyişle, görüntünün her bir pikseline bir etiket atama işlemidir. Bu durumda, aynı etiket bilgisine sahip pikseller, benzer karakteristik özellikleri paylaşmaktadırlar.

Görüntü bölütleme ile tüm görüntüyü ifade eden bir dizi bölümler veya kenarlar kümesi elde edilir. Böylece, bir bölgedeki piksellerin her biri, renk, yoğunluk veya doku gibi bazı karakteristik veya hesaplanmış özelliklere göre birbirine benzemektedir. Ayrıca, bitişik bölgeler ise karakteristik olarak önemli ölçüde farklıdır [1].

Günümüzde, pek çok görüntü bölütleme yaklaşımı bulunmaktadır. İlgili teknikler, Histogramın Ağırlık Merkezi (HAM), Otsu ve Kapur gibi yaygın olarak kullanılan eşikleme işlemleri [2-4], iteratif çalışan K-ortalama ile kümeleme [5], sıkıştırma tabanlı yöntemler [6, 7], histogram tabanlı bölütleme [8], kenar algılama [9, 10], çift kümeleme metotları [11], bölge genişletme yaklaşımları [12-16], kısmi diferansiyel denklem tabanlı çalışmalar [17-20], normalleştirilmiş kesik, rasgele yürüme, minimum kesim, izoperimetrik bölme ve minimum ağaç olarak adlandırılan grafik bölme teknikleri [21-25], çok ölçekli yaklaşımlar [26-39], yarı-otomatik yöntemler [40, 41] ve çok bantlı [42, 43] olarak literatürde geçmektedir.

En temel görüntü bölütleme yöntemi, yukarıda bahsedilen yaklaşımlardan eşik değerlendirme tekniği ile yapılmaktadır. Söz konusu metot, kümeleme işlemi için bir eşik değeri belirlemeye

dayalıdır. Bu anlamda, HAM, Otsu ve Kapur gibi birçok popüler yöntem kullanılmaktadır. Renkli görüntülerde, bahsi geçen eşiklemeler kullanılarak, üç boyutlu renk uzayını toplamda sekiz adet küçük küpler veya prizmalar şeklinde yeniden yapılandıran yaklaşım da bulunmaktadır [44].

Bu çalışmada HAM, Otsu ve Kapur eşikleme algoritmaları kullanılarak yapılan renk uzayı tabanlı kümeleme sonuçları, 100 görüntüden oluşan Weizmann tek nesneli bölütleme veritabanı yardımıyla test edilmiş ve farklı eşikleme yöntemi ile elde edilen renk kümelerine ait F-Skor değerleri ile bölütleme başarısı nicemsel olarak belirlenmiştir.

II. RENK UZAYI YARDIMIYLA GÖRÜNTÜ BÖLÜTLEME

Görüntülerde farklı bölgelere ait piksellerin, homojen bir şekilde tasnif edilmesi olarak tanımlanan görüntü bölütleme işlemi, önemli bir konudur ve veri sıkıştırma, nesne tanıma, görüntü erişimi gibi birçok uygulamada kullanılmaktadır [45]. Söz konusu süreçte, bölge büyütme yaklaşımı, yapay sinir ağları tabanlı teknikler, ağaç, olasılık ve bulanık mantık tabanlı metotlar kullanılmaktadır [46]. Ancak bahsi geçen algoritmalar, iteratif olduğundan hesapsal karmaşıklığı yüksek ve kullanıcı bağımlıdır [47].

Piksellerden hesaplanan eşik değeri ile kümelerin elde edilmesi, görüntü bölütlemesi için kullanılan önemli bir unsurdur. Gri seviyeli görüntülerde, söz konusu parametrenin belirlenmesinde, yaygın olarak HAM [2], Otsu [3] ve Kapur [4] algoritmaları kullanılmaktadır. Otsu yaklaşımında amaç fonksiyon ile sınıflar arasını maksimum veya sınıf içini minimum yapan varyans değeri dikkate alınırken, Kapur'da, her bir gri seviyedeki yerel entropy toplamını maksimize eden, iki seviyeli değeri belirlenmektedir.

Kapur tarafından önerilen amaç fonksiyon, (1)'de gösterilmiştir.

$$j(t) = H_0 + H_1 \quad (1)$$

burada H_0 ve H_1 histogramın entropilerini temsil etmektedir ve (2) ve (3)'de görüldüğü gibi hesaplanmaktadır.

$$H_0 = -\sum_{i=0}^{t-1} \frac{p_i}{\omega_0} \ln \frac{p_i}{\omega_0}, \quad \omega_0 = \sum_{i=0}^{t-1} p_i \quad (2)$$

$$H_1 = -\sum_{i=t}^{L-1} \frac{p_i}{\omega_1} \ln \frac{p_i}{\omega_1}, \quad \omega_1 = \sum_{i=t}^{L-1} p_i \quad (3)$$

Otsu yaklaşımının amaç fonksiyonu ise (4)'te görüldüğü gibidir.

$$j(t) = \sigma_0 + \sigma_1 \quad (4)$$

Denklem (4)'te görülen σ_0 ve σ_1 değerleri ise sınıfın varyansını temsil etmektedir ve (5)'deki gibi ifade edilir:

$$\sigma_0 = \omega_0 (\mu_0 - \mu_T)^2 \text{ ve } \sigma_1 = \omega_1 (\mu_1 - \mu_T)^2 \quad (5)$$

Kümelerin varyansı (6)'da verilmiştir.

$$\omega_0 = \sum_{i=0}^{t-1} p_i, \quad \mu_0 = \sum_{i=0}^{t-1} \frac{ip_i}{\omega_0} \text{ ve } \omega_1 = \sum_{i=t}^{L-1} p_i, \quad \mu_1 = \sum_{i=t}^{L-1} \frac{ip_i}{\omega_1} \quad (6)$$

burada, görüntün ortalaması μ_T


$$\mu_T = \sum_{i=0}^{L-1} ip_i \quad (7)$$

şeklindedir. HAM yöntemi ise, aşağıdaki formül ile hesaplanmaktadır:

$$T = \frac{1}{mn} \sum_{i=0}^L ip_i \quad (8)$$

Yukarıda verilen ilgili eşik belirleme yöntemleri gri seviyeli görüntülerde başarılı sonuçlar verirken, renkli görsellerde üç farklı kanal olduğundan, her biri için eşik hesaplanması zaman olarak maliyet gerektirmektedir. Ayrıca kanallardan alınan parametrelerin birleştirilerek, anlamlı kümelerin oluşturması

bir problemdir. Söz konusu mesele, her kanaldan alınan değerlere göre, Şekil 1'de gösterilen renk uzayını, alt kümelere ayırarak çözülmektedir. Böylece, her bir prizma içinde kalan pikseller aynı kümeye dâhil edilir [44].



Şekil 1. Kümelenmiş renk uzayı [44]

III. MATERYAL VE METOT

Çalışmada 100 adet görüntü içeren Weizmann tek nesneli veritabanı [48] kullanılmıştır. Bölütleme başarısının ölçülmesinde ise F-skor değerinden faydalanılmıştır. İlgili değerlerinin elde edilebilmesi için veritabanı tarafından bir ölçüm aracı da sağlanmaktadır. Şekil 2'de veritabanında yer alan görüntülerden 3 tanesi verilmiştir.



Şekil 2. Weizmann tek nesneli bölütleme veritabanı örnek görüntüleri

Bölütleme veritabanında yer alan her görüntü için kullanıcılar tarafından bölütlenmiş ve nesnelere kırmızı ile gösterildiği görseller de yer almaktadır. Şekil 2'de yer alan görüntülere ait kullanıcı işaretlemelerine birer örnek Şekil 3'de görülmektedir.



Şekil 3. Veritabanında yer alan kullanıcı bölütleme örnekleri

Çalışmada ilk olarak, yukarıda bahsi geçen 3 farklı eşikleme yaklaşımı ile 300 görüntü elde edilmiştir. Burada, her görüntü 8 küme (cluster) olarak ele alınmış ve objenin olduğu bölgede yer alan en büyük küme değerlendirilmiştir. Son olarak, tüm görüntülerde, veritabanına ait test aracıyla, söz konusu kısımlar işletilmiş ve F-skor'ları hesaplanmıştır.

F-skor sonucu, kesinlik (9) ve duyarlılık (10) değerlerinin harmonik ortalaması (11) yardımıyla hesaplanmaktadır. Duyarlılık değeri, seçilmesi gereken nesnenin ne kadarının algoritma tarafından seçildiğinin oranını, kesinlik değeri ise algoritma ile seçilen alanın doğruluk oranını belirtmektedir. Hesaplamalarda kullanılan terimler Tablo 1'de verilmiştir.

Tablo 1. F-Skor terimleri

Hesaplama		Algoritma Sonuçları	
		Nesne	Arka Fon
Kesin Referans	Nesne	TP	FN
	Arka Plan	FP	TN

TP: True Positive, FN: False Negative, FP: False Positive, TN: True Negative

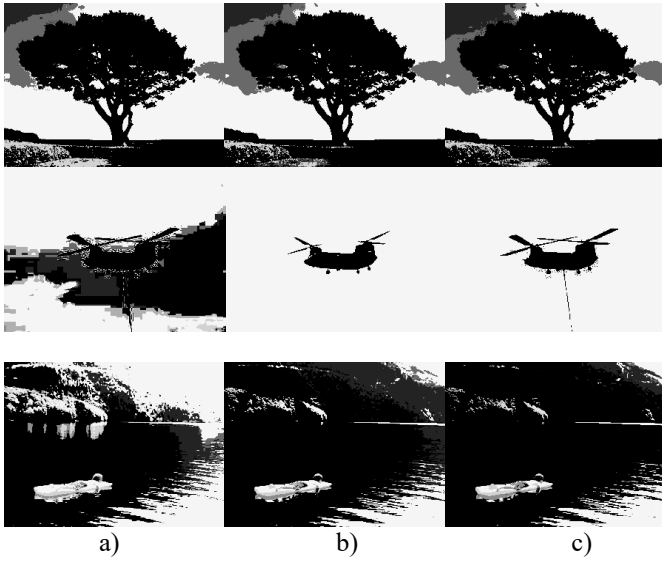
$$Kesinlik = \frac{TP}{TP+FP} \quad (9)$$

$$Duyarlılık = \frac{TP}{TP+FN} \quad (10)$$

$$F\ Skor = 2 \times \frac{Kesinlik \times Duyarlilik}{Kesinlik+Duyarlilik} \quad (11)$$

IV. DENEYSEL SONUÇLAR

Görüntüler HAM, OTSU ve KAPUR eşikleme yöntemleri ile belirlenen renk aralıklarına göre 8 kümeye ayrılmışlardır. Mevcut kümeleme sonuçları için F-skor değerleri hesaplanmıştır. Farklı eşikleme tekniklerine göre hesaplanan sonuçlar karşılaştırılarak, eşiklemenin etkileri incelenmiştir.



Şekil 4. Kümeleme sonrası ortaya çıkan sonuçlar, a) HAM sonuçları, b) OTSU sonuçları, c) KAPUR sonuçları

Şekil 4’de, Şekil 3’de yer alan görüntülere ait kümeleme sonuçları, (a), (b) ve (c) sütunlarında sırasıyla HAM, OTSU ve KAPUR eşikleme tekniklerine göre gösterilmektedir. Genel olarak nesnelerin belirlenmesinde büyük farklar ortaya çıkmasa da, arkaplan ve nesneye ait olmayan kısımlarda farklı sonuçların elde edildiği görülmektedir. Ortaya çıkan farklar Duyarlılık, Kesinlik ve F-skor değerlerinden de açıkça ortaya çıkmaktadır. İlk satırda yer alan ağaç görüntüsünün Kesinlik, Duyarlılık ve F-skor değerleri için HAM sonuçları sırasıyla 0,6954 - 0,8853 - 0,7789 olarak bulunmaktadır. Aynı sonuçlar OTSU için 0,6843 - 0,8925 - 0,7747 ve KAPUR için 0,6797 - 0,9019 - 0,7752 şeklinde ortaya çıkmaktadır. Bu sonuçlar oldukça başarılı ve birbirlerine yakın görünmektedir.

Şekil 4’de ikinci satırda yer alan helikopter görüntüsüne ait HAM sonuçlarının Kesinlik, Duyarlılık ve F-skor değerleri sırasıyla 0,1709 - 0,995 - 0,2917 olarak ortaya çıkmaktadır. Bu değerlere göre Duyarlılık oldukça yüksek görünse de Kesinlik değeri çok düşük olduğundan F-skor değeri de düşük kalmıştır. Bunun en temel sebebi, görüntüdeki helikopter nesnesinin büyük oranda işaretlenmesine karşın, arkaplan bölgelerinin de nesneye ait kümede yer almasıdır. Aynı görüntüye ait Kesinlik, Duyarlılık ve F-skor değerleri OTSU ile 1,000 - 0,7618 - 0,8648 ve KAPUR ile 0,9575 - 0,9595 - 0,9585 olarak elde edilmiştir. Bu görüntü için KAPUR yönteminin çok daha başarılı olduğu hem görüntü üzerinden hem de F-skor değeri ile açıkça görülmektedir.

Şekil 4’de üçüncü satırda yer alan görüntüde ise her üç yöntem için de sonuçları oldukça düşük kaldığı görülmektedir. Söz konusu görüntünün HAM ile elde edilen Kesinlik, Duyarlılık ve F-skor değerleri sırasıyla 0,2902 - 0,2679 - 0,2786 olarak belirlenmiştir. Aynı değerler OTSU için 0,7675 - 0,2384 - 0,3638 ve KAPUR için 0,6242 - 0,2829 - 0,3894 olarak ortaya çıkmıştır. Bu görüntü için de yine en düşük Kesinlik değeri HAM ile elde edilmiştir.

Tablo 2. Kümeleme işleminin test sonuçları

Yöntem	Duyarlılık	Kesinlik	F-skor
HAM	0,5734	0,6688	0,5661
OTSU	0,7019	0,6309	0,6187
KAPUR	0,7172	0,6365	0,6213

Veritabanında yer alan 100 görüntüye ilişkin sonuçların ortalamaları Tablo 2’de görülmektedir. Elde edilen sonuçlara göre, en başarılı eşikleme yöntemi 0,6213 F-skor ortalama değeri ile KAPUR olarak ortaya çıkmıştır. İkinci sırada 0,6187 ile OTSU ve son sırada 0,5661 ile HAM tekniği yer almaktadır. Ancak Tablo 2’de yer alan veriler, Kesinlik ve Duyarlılık değerleri açısından incelendiğinde bazı farklılıklar olduğu göze çarpmaktadır. Duyarlılık açısından F-skor ile uyumlu bir görünüm ortaya çıksa da Kesinlik açısından sıralama tamamen değişmektedir. HAM yöntemi ile elde edilen Kesinlik değerinin, KAPUR ve OTSU yöntemlerine göre daha başarılı olduğu belirgindir.

V. TARTIŞMA VE SONUÇ

Bu çalışmada, renk uzayı tabanlı kümeleme işlemi için 3 farklı eşikleme yaklaşımı kullanılarak, eşikleme yöntemlerinin başarımları ölçülmüştür. Başarımlar ölçülürken 100 görüntüden oluşan Weizmann tek nesneli bölütleme veritabanı kullanılmış ve sonuçlar Kesinlik, Duyarlılık ve F-skor olarak elde edilmiştir.

Elde edilen sonuçlara göre Duyarlılık ve F-skor açısından en başarılı yöntem KAPUR iken en başarısız olan yöntemin HAM olduğu ortaya çıkmıştır. Ancak Kesinlik açısından bakıldığında HAM tekniğinin çok daha başarılı olduğu görülmektedir. Bunun nedeninin ise aynı kümede yer alan ancak nesneden bağımsız bölgelerin de nesne olarak işaretlenmesi olduğu görülmektedir.

İlerideki çalışmalarda, kümeleme sonucunda ortaya çıkan kümeler arasındaki uzamsal ilişkiler dikkate alınarak ve küçük bölgeler birleştirilerek bölütleme işlemi yapılması ve bu bölütleme sonuçlarının incelenmesi planlanmaktadır. Böylece,

Keskinlik ve Duyarlılık değerleri ile birlikte F-skor değerindeki değişimler incelenerek, bölütleme başarısının çok daha belirgin şekilde ortaya çıkarılması mümkün olabilecektir.

KAYNAKLAR

- [1] L. G. Shapiro and G. C. Stockman, *Computer Vision*, New Jersey, Prentice-Hall, ISBN 0-13-030796-3, pp. 279-325, 2001.
- [2] R. Demirci, "Fuzzy adaptive anisotropic filter for medical images", *Expert Systems*, Vol. 27(3), pp. 219-229, 2010.
- [3] N. Otsu, "A threshold selection method from gray-level histograms", *IEEE Trans. Sys., Man., Cyber*, Vol. 9(1), pp. 62-66, 1979.
- [4] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram", *Computer Vision, Graphics and Image Processing*, Vol. 29(3), pp. 273-285, 1985.
- [5] L. Barghout and J. Sheynin, "Real-world scene perception and perceptual organization: Lessons from Computer Vision", *Journal of Vision*, Vol. 13(9), pp. 709-709, doi:10.1167/13.9.709, 2013.
- [6] H. Mobahi, S. Rao, A. Yang, S. Sastry and Y. Ma, "Segmentation of natural images by texture and boundary compression", *International Journal of Computer Vision*, Vol. 95, pp. 86-98, doi:10.1007/s11263-011-0444-0, 2011.
- [7] S. Rao, H. Mobahi, A. Yang, S. Sastry and Y. Ma, "Natural image segmentation with adaptive texture and boundary encoding", in *Asian Conference on Computer Vision (ACCV) 2009, H. Zha, R.-i. Taniguchi, and S. Maybank (Eds.), Part I, LNCS 5994*, pp. 135-146, 2009.
- [8] R. Ohlander, K. Price, D. R. Reddy, "Picture segmentation using a recursive region splitting method", *Computer Graphics and Image Processing*, Vol. 8(3), pp. 313-333. doi:10.1016/0146-664X(78)90060-6, 1978.
- [9] S. Osher and N. Paragios, *Geometric Level Set Methods in Imaging, Vision, and Graphics*, Springer-Verlag New York, pp. 59-77, 2003.
- [10] T. Lindeberg and M. Li, "Segmentation and classification of edges using minimum description length approximation and complementary junction cues", Department of Numerical Analysis and Computer Science, KTH (Royal Institute of Technology), SE-100 44 Stockholm, Sweden, Tech. Rep., pp. 1-19, Jan 1996.
- [11] S. Guberman, V. V. Maximov, A. Pashintsev, "Gestalt and image understanding", *Gestalt Theory*, Vol. 34(2), pp. 143-166, 2012.
- [12] R. Nock and F. Nielsen, "Statistical region merging", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26(11), pp. 1452-1458, 2004.
- [13] L. Chen, H. D. Cheng and J. Zhang, "Fuzzy subfiber and its application to seismic lithology classification", *Information Sciences: Applications*, Vol. 1(2), pp. 77-95, 1994.
- [14] S. L. Horowitz and T. Pavlidis, "Picture segmentation by a directed split and merge procedure", in *Proc. ICPR*, Denmark, pp.424-433, 1974.
- [15] S. L. Horowitz and T. Pavlidis, "Picture segmentation by a tree traversal algorithm", *Journal of the ACM*, Vol. 23(2), pp. 368-388, 1976.
- [16] L. Chen, "The lambda-connected segmentation and the optimal algorithm for split-and-merge segmentation", *Chinese J. Computers*, Vol. 14(5), pp 321-331, 1991.
- [17] V. Caselles, R. Kimmel and G. Sapiro, "Geodesic active contours", *International Journal of Computer Vision*, Vol. 22(1), pp. 61-79, 1997.
- [18] S. Osher and N. Paragios, *Geometric Level Set Methods in Imaging Vision and Graphics*, Springer Verlag, ISBN 0-387-95488-0, 2003.
- [19] (2017) J. A. Sethian, "Segmentation in Medical Imaging", [Online]. Available: https://math.berkeley.edu/~sethian/2006/Applications/Medical_Imaging/artery.html.
- [20] N. Forcade, G. Le Guyader and C. Gout, "Generalized fast marching method: applications to image segmentation", *Numerical Algorithms*, Vol. 48(1-3), pp. 189-211, doi:10.1007/s11075-008-9183-x, July 2008.
- [21] J. Shi and J. Malik, "Normalized cuts and image segmentation", *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 22(8), pp. 888-905, 2000.
- [22] L. Grady, "Random walks for image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 28(11), pp. 1768-1783, 2006.
- [23] Z. Wu and R. Leahy, "An optimal graph theoretic approach to data clustering: Theory and its application to image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 15(11), pp. 1101-1113, 1993.
- [24] L. Grady and E. L. Schwartz, "Isoperimetric graph partitioning for image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 28(3), pp. 469-475, 2006.
- [25] C. T. Zahn, "Graph-theoretical methods for detecting and describing gestalt clusters", *IEEE Transactions on Computers*, Vol. 20(1), pp. 68-86, 1971.
- [26] A. Witkin, "Scale-space filtering", in *Proc. 8th Int. Joint Conf. Art. Intell.*, Karlsruhe, Germany, pp. 1019-1022, 1983.
- [27] A. Witkin, "Scale-space filtering: a new approach to multi-scale description", in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Processing (ICASSP)*, Vol. 9, pp. 150-153, Mar. 1984.
- [28] J. Koenderink, "The structure of images", *Biological Cybernetics*, Vol. 50, pp. 363-370, 1984.
- [29] L. Lifshitz and S. Pizer, "A multiresolution hierarchical approach to image segmentation based on intensity extrema", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 12(6), pp. 529-540, 1990.
- [30] T. Lindeberg, "Detecting salient blob-like image structures and their scales with a scale-space primal sketch: A method for focus-of-attention", *International Journal of Computer Vision*, Vol. 11(3), pp. 283-318, 1993.
- [31] T. Lindeberg, *Scale-space theory in computer vision*, *Kluwer Academic Publishers*, ISBN 0-7923-9418-6, 1994.
- [32] J. Gauch and S. Pizer, "Multiresolution analysis of ridges and valleys in grey-scale images", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 15(6), pp. 635-646, 1993.
- [33] O. Olsen and M. Nielsen, "Multi-scale gradient magnitude watershed segmentation", in *Proc. of ICIAIP 97, Florence, Italy, Lecture Notes in Computer Science*, pp. 6-13, September 1997.
- [34] E. Dam, P. Johansen, O. Olsen, A. Thomsen, T. Darvann, A. Dobrzenieck, N. Hermann, N. Kitai, S. Kreiborg, P. Larsen and M. Nielsen, "Interactive multi-scale segmentation in clinical use", in *European Congress of Radiology*, 2000.
- [35] K. Vincken, A. Koster and M. Viergever, "Probabilistic multiscale image segmentation", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 19(2), pp. 109-120, 1997.
- [36] M. Tabb and N. Ahuja, "Unsupervised multiscale image segmentation by integrated edge and region detection", *IEEE Transactions on Image Processing*, Vol. 6(5), pp. 642-655, 1997.
- [37] E. Akbas and N. Ahuja, "From ramp discontinuities to segmentation tree", in *Asian Conference on Computer Vision*, pp. 123-134, September 2009.
- [38] C. Undeman and T. Lindeberg, "Fully automatic segmentation of MRI brain images using probabilistic anisotropic diffusion and multi-scale watersheds", in *Proc. Scale-Space'03, Isle of Skye, Scotland, Springer Lecture Notes in Computer Science*, Vol. 2695, pp. 641-656, 2003.
- [39] L. Florack and A. Kuijper, "The topological structure of scale-space images", *Journal of Mathematical Imaging and Vision*, Vol. 12(1), pp. 65-79, 2000.
- [40] L. Barghout, "Visual taxometric approach to image segmentation using fuzzy-spatial taxon cut yields contextually relevant regions", in *International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems*, pp. 163-173, July 2014.
- [41] L. Barghout, "Vision: how global perceptual context changes local contrast processing", Ph.D. Dissertation, 2003.
- [42] Z. M. Saygin, D. E. Osher, J. Augustinack, B. Fischl and J. D. E. Gabrieli, "Connectivity-based segmentation of human amygdala nuclei using probabilistic tractography", *Neuroimage*, Vol. 56(3), pp. 1353-61, 2011.
- [43] R. A. Menke, S. Jbadi, K. L. Miller, P. M. Matthews and M. Zarei, "Connectivity-based segmentation of the substantia nigra in human and its implications in Parkinson's disease", *Neuroimage*, Vol. 52(4), pp. 1175-80, 2010.
- [44] R. Demirci, U. Güvenç and H. T. Kahraman, "Görüntülerin renk uzayı yardımıyla ayrıştırılması", *İleri Teknoloji Bilimleri Dergisi*, Vol. 3(1), pp. 1-8, 2014.
- [45] X. Y. Wang, Z. F. Wu, L. Chen, H. L. Zheng and H. Y. Yang, "Pixel classification based color image segmentation using quaternion exponent moments", *Neural Networks*, Vol. 74, pp. 1-13, 2016.
- [46] H. D. Cheng, X. H. Jiang, Y. Sun and J. Wang, "Color image segmentation: advances and prospects", *Pattern recognition*, Vol. 34(12), pp. 2259-2281, 2001.
- [47] U. Güvenç, Ç. Elmas and R. Demirci, "Renkli görüntülerin otomatik ayrıştırılması", *Politeknik Dergisi*, Vol. 11(1), pp. 9-12, 2008.
- [48] S. Alpert, M. Galun, R. Basri and A. Brandt, "Image segmentation by probabilistic bottom-up aggregation and cue integration", *IEEE transactions on pattern analysis and machine intelligence*, Vol. 34(2), pp. 315-327, 2012.