

## Renk İndirgeme ve Kenar Belirleme Yardımıyla SRG Tabanlı Görüntü Bölütleme

Mürsel Ozan İncetas<sup>1</sup>

Murat Meriçelli<sup>2</sup>

### Özet

Görüntü bölütleme, görüntü işlemedeki en temel çalışma konularından biridir. Literatürde pek çok bölütleme çalışması bulunmakla birlikte, günümüzde farklı görüntü işleme tekniklerinin bir arada kullanıldığı yaklaşımların ön plana çıktığı görülmektedir. Bu çalışmada renk indirgeme, kenar belirleme ve bölge genişletmeyi temel alan yeni bir yaklaşım önerilmiştir. Bu üç aşamalı yaklaşımın birinci aşamasında renk indirgeme işlemi yapılmaktadır. Her bir renk kanalı üzerinde eşit aralıklı çoklu eşik seçimi gerçekleştirilmektedir. İkinci aşamada, indirgenmiş renkli görüntü üzerinde kenar belirleme işlemi yapılmaktadır. Böylece kenar içermeyen piksellerden oluşan bölgeler elde edilmektedir. Söz konusu bölgeler, bölge genişletme yardımıyla genişletilerek, birbirine en benzer piksellerin bir arada olması sağlanmaya çalışılmıştır. Yaklaşımın başarısı, 100 adet renkli görüntü içeren Weizmann tek nesneli görüntü veri seti üzerinde test edilmiştir. MATLAB üzerinde, elde edilen kesinlik (Precision), duyarlılık (Recall) ve F-skor (F-score) sonuçları, indirgeme aşamasında kullanılan farklı eşik sayıları ile karşılaştırılmıştır. Sonuç olarak, renk sayının artışının bölütleme başarısını düşürdüğü belirlenmiştir. Gelecekte, farklı indirgeme ve kenar belirleme yöntemlerinin kullanıldığı ve nesneye ait piksellerin detaylı seçimine odaklanan çalışmaların gerçekleştirilmesi hedeflenmektedir.

1 Doç. Dr., Alanya Alaaddin Keykubat Üniversitesi, ozan.incetas@alanya.edu.tr, 0000-0002-1016-1655

2 Dr. Öğr. Üyesi, Kastamonu Üniversitesi, mmericelli@kastamonu.edu.tr, 0000-0003-0168-3221

## 1. Giriş

Görüntü işleme alanı, dijital verilerin analizi ve anlamlandırılması sürecinde, hızla gelişen ve değişen bir araştırma konusudur. Günümüzde, görüntü işleme teknolojileri; tıp, güvenlik, tarım, eğlence ve robotik gibi çeşitli sektörlerde kritik bir rol oynamaktadır. Bu alanın temel konularından biri olan görüntü bölütleme, görüntüdeki nesnelere ya da ilgi alanlarını diğer kısımlardan ayırmayı hedefler [1]. Bölütleme sürecinde, görüntünün özelliklerinin çıkarılması ve daha anlamlı bir forma dönüştürülmesi, analiz ve karar verme süreçlerinin doğruluğunu doğrudan etkiler [2-4]. Bu bağlamda, renk indirgeme (color quantization) ve kenar belirleme (edge detection) gibi teknikler, görüntü işleme zincirinde kritik öneme sahiptir ve gelişmiş bölütleme algoritmalarının temel yapı taşlarını oluşturur. Renk indirgeme, bir görüntünün renk yoğunluğunu azaltarak daha sade ve işlenebilir bir yapı oluşturmayı amaçlar [5]. Görüntüdeki farklı tonların daha az sayıda temsilci renk grubuna indirgenmesi, hem işlem hızını artırır hem de depolama maliyetlerini düşürür. Özellikle yüksek çözünürlüklü ve çok renkli görüntülerde, renk indirgeme işlemi, görüntüdeki anlamlı bölgelerin belirlenmesini kolaylaştırır. Bu yaklaşım, genellikle görüntünün genel yapısını korurken, veri kaybını en aza indirmeyi hedefler [6]. Renk indirgeme teknikleri, sınırlı kaynaklarla çalışılan uygulamalarda ve gerçek zamanlı işlem gerektiren senaryolarda büyük avantaj sağlar. Kenar belirleme ise, görüntüdeki nesnelere sınırlarını tespit ederek, şekil, boyut ve konum gibi geometrik özelliklerin çıkarılmasını sağlar [7-9]. Kenarların doğru bir şekilde belirlenmesi, bir nesnenin diğerinden ayrılmasını kolaylaştırır ve bölütleme sürecinin doğruluğunu artırır. Sobel, Canny ve Laplace gibi kenar belirleme algoritmaları, farklı görüntü tiplerine ve uygulamalara uygun şekilde uyarlanabilen esnek araçlardır. Bu tekniklerin etkinliği, özellikle gürültülü ya da karmaşık arka plana sahip görüntülerde daha da önemli hale gelir. Kenar belirleme, sadece bölütleme için değil, aynı zamanda nesne tanıma [10], görüntü filtre uygulamaları [11], hareket algılama [12] ve görüntü enterpolasyonu [13] gibi ileri seviye görüntü işleme uygulamaları için de kritik bir aşamadır.

Çekirdekli bölge genişletme (SRG - Seeded Region Growing) tabanlı görüntü bölütleme, dijital görüntülerde belirli nesnelere ya da bölgelere tespit etmek için kullanılan bir tekniktir. Bu yöntem, önceden tanımlanmış başlangıç noktaları (tohumlar) ile çalışır ve komşu piksellerin özelliklerine dayanarak benzerlik analizine dayalı bir şekilde bölge genişletir. SRG'nin avantajları arasında, gürültüye dayanıklı olması ve bölütleme sonuçlarının başlangıç tohumlarına bağlı olarak hassas bir şekilde kontrol edilebilmesi yer alır. SRG, medikal görüntüleme, nesne tespiti, uydu görüntü analizi

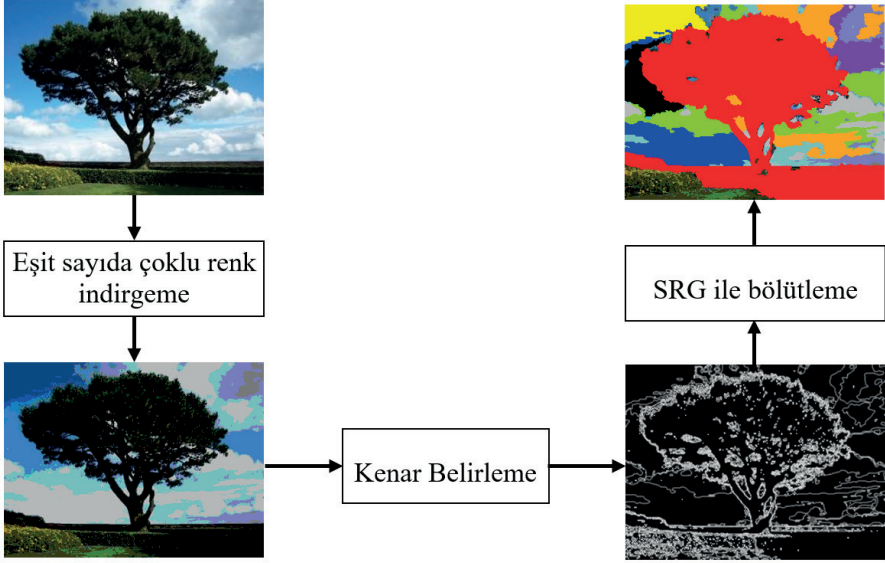
ve çeşitli bilgisayarla görme uygulamalarında yaygın olarak kullanılır. Bu yöntem, özellikle homojen bölgeler içeren görüntülerde etkili bir performans sunar. Literatürde SRG, kenar ve renk indirgeme yöntemlerine dayalı birçok bölütleme çalışması bulunmaktadır. Frank ve Suxian renkli görüntü segmentasyonu için otomatik tohumlanmış bölge genişletme algoritmasını 2005 yılında sunmuşlardır. İlk olarak, giriş RGB renkli görüntü YCbCr renk uzayına dönüştürmüşler ve akabinde başlangıç tohumları otomatik olarak seçilmiştir. Son olarak, benzer veya küçük bölgeleri birleştirmek için bölge birleştirme kullanılmıştır. Deneysel sonuçlar, algoritmanın bazı mevcut algoritmalarla karşılaştırıldığında olumlu sonuçlar üretebildiğini göstermiştir [14]. Feng ve arkadaşları 2020 yılında bulanık C-ortalama (FCM) algoritmasına dayalı etkili bir bölütleme çalışması dikkat çekmektedir. Geliştirilen söz konusu yöntemde öncelikle arka plan ve nesne ayrımı yapılmıştır. Sonra, hem nesnenin hem de arka plan histogramının tepe değerlerinin sayısı hesaplanarak, bölgesel belirgin renklerin niceliği elde edilmiştir. Başka bir ifade ile renk indirgeme kullanılmıştır. Renk sayısı, FCM algoritmasının kümeleme merkezlerinin sayısıdır. Berkeley segmentasyon veri kümesi kullanılarak yapılan deneylere incelendiğinde ilgili yöntemin etkili bir segmentasyon yöntemi olduğunu kanıtlanmıştır.. Algoritma, yüksek kalitede, kararlı ve doğru renkli görüntü segmentasyon sonuçları elde edebilmektedir [15]. Dermatoskopik görüntü segmentasyonu uygulamaları için genişletilmiş bir GrabCut görüntü segmentasyonu algoritması önerilen çalışmada benzer şekilde renk indirge algoritmasından faydalanılmıştır. Yöntem, sekizli ağaç renk indirgeme ve yeni bir enerji fonksiyonuyla değiştirilmiş bir GrabCut yöntemini entegre ederek başarılı bir tıbbi görüntü segmentasyon çalışmasına örnektir. Çeşitli veritabanları üzerinde gerçekleştirilen ve yaygın olarak kullanılan segmentasyon araçlarıyla hem nitel hem de nicel değerlendirmelerde olumlu bir şekilde karşılaştırıldığı gösterilmiştir [16]. Bir diğer makalede, yerel histogramlara dayalı yeni bir görüntü segmentasyonu yöntemi önerilmiştir. Kümeleme tabanlı renk indirgeme ile, yeterli sayıda temsili renk çıkarılarak başlanan çalışmada, her piksel için dairesel bir yerleşimde yerel bir histogram elde edilmiştir. Dairesel yerleşim birkaç ölçeğe genişletildikten sonra, uygun bir ölçeğe sahip yerel bir histogram, görüntü segmentasyonu için karşılık gelen pikselde bir renk-doku tanımlayıcısı olarak benimsenmiştir. Hem sentetik hem de doğal renk-doku görüntüleri üzerinde deneyler gerçekleştirilmiştir. Deneysel bulgular değerlendirildiğinde önerilen yöntemin, özellikle dokulu alanlarda, görüntü segmentasyonunda en son yöntemlere kıyasla çok daha iyi performans gösterdiği açıkça görülmüştür [17]. Geliştirilmiş kenar algılama algoritması kullanılan 2015 yılında önerilen makalede beyin tümörü

segmentasyonu gerçekleştirilmiştir. İlgili yaklaşım, Sobel kenar algılamaya dayanmaktadır. Sobel yöntemini görüntü bağımlı eşikleme yöntemiyle birleştirilmiş ve kapalı kontur algoritması kullanarak farklı bölgeler bulunmuştur. Son olarak, tümörler kapalı konturlar içindeki yoğunluk bilgisi kullanılarak görüntüden çıkarılmıştır. Algoritmanın performansı hem nesnel hem de öznel olarak ölçülmüştür. Simülasyon sonuçları, önerilen algoritmanın geleneksel segmentasyon yöntemlerine göre üstün performans verdiğini göstermektedir. Karşılaştırmalı analiz için, önerilen yöntemin geleneksel yöntemlere göre üstünlüğünü göstermek için çeşitli parametreler kullanılmıştır [18]. Narkhede ve Gökhale 2015 yılında önerdikleri çalışma renkli görüntünün segmentasyonu için kenar algılama ve bölge genişletmeyi kullanan bütünleşmiş bir yaklaşım sunmaktadır. Önerilen bahsi geçen yöntem, kenar bilgisine dayalı otomatik tohum seçimini içermektedir. Seçilen tohum piksellerine göre, piksellerin renk benzerliğine ve bağlantısına dayalı bölge genişletme gerçekleştirilmiştir. İlgili yöntem, birçok renkli görüntü için etkili ve verimli sonuçlar sağlamıştır [19]. 2022 yılında meme kanseri tanı modeli için bir segmentasyon modeli önerilmiştir. Makale öncelikle, bir makine öğrenme yaklaşımı kullanılarak memenin mamogram görüntülerine dayalı tümörleri teşhis etmek için etkili bir yöntem önermeyi amaçlamıştır. Çalışmada çekirdekli bölge genişletme (SRG) algoritması kullanılarak görüntü segmentasyonu, farklı özellik çıkarma sınıfları kullanılarak özellik çıkarma ve sıralı ileri seçim tekniği kullanılarak önemli ve etkili özellik seçimi olmak üzere beş adımdan geçirilmesiyle gerçekleştirilmiştir ve son olarak Destek Vektör Makinesi (SVM) algoritması iki sınıflandırma seviyesinde ikili bir sınıflandırıcı olarak kullanılmıştır. Önerilen yöntemin pratik uygulaması ve grafiksel kullanıcı arayüzü (GUI) CAD aracı MATLAB yazılımı kullanılarak gerçekleştirilmiştir. Deneysel sonuçlar önerilen yöntemin normal ve anormal mamogram görüntüleri olarak sınıflandırma doğruluğunun %100'e ulaştığını, iyi huylu ve kötü huylu için sınıflandırma doğruluğunun ise %87,1'e eşit olduğunu göstermiştir [20].

Bu çalışmada renkli görüntüler için çoklu renk indirgeme, kenar belirleme ve SRG tabanlı bir bölütleme tekniği önerilmiş ve bu tekniğin performansı incelenmiştir. Deneysel Weizmann [21] tek nesnel renkli görüntü veri seti kullanılmıştır. Bölütleme sonucunda elde edilen görüntüler Weizmann değerlendirme yazılımı yardımıyla MATLAB üzerinde değerlendirilmiştir. Kesinlik (Presicion), duyarlılık (Recall) ve F-skor (F-score) olarak elde edilen sonuçlar, indirgeme için kullanılan eşik sayılarına göre karşılaştırılmıştır.


## 2. Önerilen Yöntem

Önerilen yaklaşımın ilk adımında çoklu indirgeme işlemi gerçekleştirilmiştir. Çoklu indirgeme için eşit aralıklı (uniformly) renk indirgeme yaklaşımı kullanılmıştır. Her renk kanalı eşit sayıda (3, 4, 5 ve 6) ayrı gri seviye değerine indirgenmiş ve sırasıyla 27, 64, 125 ve 216 farklı renk değerine sahip görüntüler elde edilmiştir. Ardından komşu pikseller arasındaki Öklid mesafesi ile indirgenmiş görüntülerdeki kenarlar ortaya çıkarılmıştır. İndirgenmiş görüntüler üzerinde, kenar pikseller dışında kalan komşu pikseller birleştirilerek çekirdek bölgeler elde edilmiştir. Son olarak da SRG tekniği yardımıyla bölgeler genişletilmiştir. Önerilen yöntemin akış diyagramı Şekil 1'de görülmektedir.




Şekil 1. Önerilen yöntemin akış diyagramı

Şekil 1'de de görüldüğü gibi önerilen yöntemin ilk adımında, renk indirgeme işlemi yapılmaktadır. Bu çalışmada, her bir renk kanalı için 2, 3, 4 ve 5 adet eşit aralıklı eşik seçimi uygulanmıştır. Böylece her bir renk kanalı 3, 4, 5 ve 6 eşit parçaya bölünmüştür. Bu renk kanalları tekrar bir araya getirilerek 27, 64, 125 ve 216 farklı renk değerlerine sahip renkli görüntüler elde edilmiştir. Renk indirgeme işlemi için örnek görüntüler Şekil 2'de görülmektedir.




Şekil 2. Renk indirgeme sonuçları, a) 27 renk, b) 64 renk, c) 125 renk, d) 216 renk

Renk indirgeme işleminin ardından, kenar belirleme adımı uygulanmıştır.  $3 \times 3$ 'lük maske içerisindeki merkez pikselin komşuları ile arasındaki Öklid mesafesinin ortalaması, aynı pikselin kenar görüntüsündeki gri seviye değeri olarak atanmıştır. Böylece aynı renk değerlerine sahip pikseller 0 gri seviye değeri yani siyah renk ile gösterilmiştir. Kenar piksellerin gri seviye değerleri ise daha yüksek olarak elde edilmiştir. Şekil 3'de elde edilen kenar görüntülerine ilişkin örnekler verilmiştir.



Şekil 3. Kenar belirleme sonuçları, a) 27 renk, b) 64 renk, c) 125 renk, d) 216 renk

Son aşamada ise gri seviye değeri 0 olan pikseller seçilerek, indirgenmiş renkli görüntü üzerinden SRG tekniği yardımıyla bölge genişletme işlemi yapılmıştır. Bu işlem ile birbirine en benzer pikseller, ilgili bölgeye atanmaktadır. Ayrıca aynı renk değerine sahip komşu bölgeler birleştirilmiştir. Son olarak da görüntüdeki nesne üzerinde rastgele seçilmiş bir noktanın içerisinde bulunduğu bölge boyanarak karşılaştırma için kaydedildi. Elde edilen nesne bölgesi örnekleri Şekil 4'de görülmektedir.



Şekil 3. Bölütleme sonucu nesne örneği, a) 27 renk, b) 64 renk, c) 125 renk, d) 216 renk

### 3. Deneysel Bulgular

Yapılan çalışma Weizmann tek nesnel renkli görüntü veri seti üzerinde gerçekleştirilmiştir. Veri setinde her görüntü içerisinde 1 adet nesne olmak üzere 100 adet renkli görüntü bulunmaktadır. Şekil 3'te görüldüğü gibi boyanan görüntüler, Weizmann veri setinde yer alan değerlendirme modülü ile değerlendirilmiştir. Söz konusu modül, her bir sonuç görüntüsünü veri setinde yer alan doğrulama görüntüleri ile karşılaştırmaktadır. Sonuçlar ise kesinlik, duyarlılık ve F-skor olarak elde edilmektedir. İndirgenen renk sayısına göre elde edilen bölütleme sonuçları, her 100 resim için ortalama olarak Tablo 1'de verilmiştir.

İndirgenmiş Renk Sayısı	Kesinlik	Duyarlılık	F-skor
27	0,4743	0,8553	0,5694
64	0,4129	0,8768	0,5268
125	0,3419	0,8593	0,4571
216	0,2924	0,8761	0,4091

Duyarlılık değeri, nesne olarak işaretlenen piksellerin ne kadarının gerçek nesne üzerinde olduğunu gösterir. Kesinlik değeri ise gerçek nesnenin piksellerinin ne kadarının bulunduğunu ifade eder. Kesinlik ile duyarlılık değerlerinin harmonik ortalaması ise F-skor değerini belirler. Tablo 1'de verilen sonuçlarda ilk göz çarpan duyarlılık değerlerinin oldukça yüksek olduğudur. Buna göre, görüntülerde nesne olarak işaretlenen pikseller, büyük oranda doğrudur. Kısaca büyük çoğunluğu gerçek nesne üzerinde yer almaktadır. Ancak gerçek nesnenin seçimi söz konusu olduğunda, yani kesinlik değerleri incelendiğinde başarının genel olarak düştüğü görülmektedir. Her ne kadar bu durum, rastgele nokta seçimi ile alakalı olsa da indirgenmiş renk sayısı arttıkça Kesinlik değerinde önemli bir düşüş görülmektedir. Dolayısıyla indirgenmiş renk sayısının az olmasının SRG tabanlı başarı üzerinde önemli bir etkiye sahip olduğu açıkça görülmektedir.

### 4. Sonuç

Bu çalışmada renk indirgeme, kenar belirleme ve SRG tabanlı bölütlemeye dayalı yeni bir yaklaşım önerilmiştir. Önerilen yaklaşım ile eşit sayıda çoklu eşiklemeler yapılarak, görüntüler farklı sayıda renklere indirgenmiş ve renk sayısı azaltılan görüntüler üzerinde kenar belirleme yapılmıştır. Kenar olmayan piksellerin çekirdek olarak seçilmesinin ardından bölge genişletmeye dayalı bölütleme işlemi gerçekleştirilmiştir. Ayrıca başarı değerlendirmesi için 100 adet renkli görüntüden oluşan Weizmann tek nesnel görüntü veri seti



kullanılmıştır. Önerilen yaklaşım ile yapılan testlerde, renk sayının artmasının bölütleme başarısını düşürdüğü gözlemlenmiştir. Ancak bu sonuca etki eden pek çok faktör bulunmaktadır. Bunların başında indirgeme işlemi için eşit aralıklı eşikler seçilmesidir. Renk indirgeme amacıyla literatürde pek çok çalışma olduğu bulunmaktadır. Ayrıca kenar belirleme işlemi için doğrudan Öklid uzaklığı kullanılmıştır. Son olarak da nesneye ait bölgenin belirlenmesinde nesne üzerinde rastgele seçilen bir nokta temel alınmıştır. Bunların tamamı da başarıya etki edebilecek durumlardır. Bu nedenle gelecekte, farklı indirgeme ve kenar belirleme tekniklerinin kullanıldığı ve nesneye ait piksellerin detaylı seçimini içeren çalışmaların yapılması planlanmaktadır.



## Kaynaklar

- [1] Y. Yu *et al.*, “Techniques and challenges of image segmentation: A review,” *Electronics*, vol. 12, no. 5, p. 1199, 2023.
- [2] S. Minaee, Y. Boykov, F. Porikli, A. Plaza, N. Kehtarnavaz, and D. Terzopoulos, “Image segmentation using deep learning: A survey,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 44, no. 7, pp. 3523-3542, 2021.
- [3] X. Zhang, Q. Yao, J. Zhao, Z. Jin, and Y. Feng, “Image semantic segmentation based on fully convolutional neural network,” *Comput. Eng. Appl*, vol. 44, pp. 45-57, 2022.
- [4] A. Garcia-Garcia, S. Orts-Escolano, S. Oprea, V. Villena-Martinez, P. Martinez-Gonzalez, and J. Garcia-Rodriguez, “A survey on deep learning techniques for image and video semantic segmentation,” *Applied Soft Computing*, vol. 70, pp. 41-65, 2018.
- [5] M. Kılıçaslan and M. O. İncetaş, “Adaptive Color Quantization Method with Multi-level Thresholding,” *International Journal of Computational Intelligence Systems*, vol. 16, no. 1, p. 7, 2023.
- [6] M. Kılıçaslan, U. Tanyeri, and R. Demirci, “Image Retrieval using One-Dimensional Color Histogram Created with Entropy,” *Advances in Electrical & Computer Engineering*, vol. 20, no. 2, 2020.
- [7] X. Pang, C. Lin, F. Li, and Y. Pan, “Bio-inspired XYW parallel pathway edge detection network,” *Expert Syst Appl*, vol. 237, p. 121649, 2024.
- [8] U. Tanyeri, M. Kılıçaslan, and R. Demirci, “Canny edge detector with half entropy,” in *2019 3rd international symposium on multidisciplinary studies and innovative technologies (ISMSIT)*, 2019: IEEE, pp. 1-4.
- [9] N. You, L. Han, D. Zhu, and W. Song, “Research on image denoising in edge detection based on wavelet transform,” *Applied Sciences*, vol. 13, no. 3, p. 1837, 2023.
- [10] M. C. Shin, D. B. Goldgof, and K. W. Bowyer, “Comparison of edge detector performance through use in an object recognition task,” *Computer Vision and Image Understanding*, vol. 84, no. 1, pp. 160-178, 2001.
- [11] M. Kılıçaslan, “Adaptive threshold selection of anisotropic diffusion filters using spiking neural network model,” *Signal, Image and Video Processing*, vol. 18, no. 1, pp. 407-416, 2024.
- [12] J. R. Bergen, P. Anandan, K. J. Hanna, and R. Hingorani, “Hierarchical model-based motion estimation,” in *Computer Vision—ECCV’92: Second European Conference on Computer Vision Santa Margherita Ligure, Italy, May 19–22, 1992 Proceedings 2*, 1992: Springer, pp. 237-252.

- [13] M. Kılıçaslan, "Image interpolation with spiking neural network based pixel similarity," *Signal, Image and Video Processing*, vol. 18, no. 10, pp. 6925-6936, 2024.
- [14] F. Y. Shih and S. Cheng, "Automatic seeded region growing for color image segmentation," *Image Vision Comput*, vol. 23, no. 10, pp. 877-886, 2005.
- [15] L. Feng, H. Li, Y. Gao, and Y. Zhang, "A color image segmentation method based on region salient color and fuzzy c-means algorithm," *Circuits, Systems, and Signal Processing*, vol. 39, pp. 586-610, 2020.
- [16] V. Frants and S. Agaian, "Dermoscopic image segmentation based on modified GrabCut with octree color quantization," in *Mobile Multimedia/Image Processing, Security, and Applications 2020*, 2020, vol. 11399: SPIE, pp. 119-130.
- [17] Y. Liu, G. Liu, C. Liu, and C. Sun, "A novel color-texture descriptor based on local histograms for image segmentation," *Ieee Access*, vol. 7, pp. 160683-160695, 2019.
- [18] A. Aslam, E. Khan, and M. S. Beg, "Improved edge detection algorithm for brain tumor segmentation," *Procedia Computer Science*, vol. 58, pp. 430-437, 2015.
- [19] P. R. Narkhede and A. V. Gokhale, "Color image segmentation using edge detection and seeded region growing approach for CIELab and HSV color spaces," in *2015 International Conference on Industrial Instrumentation and Control (ICIC)*, 2015: IEEE, pp. 1214-1218.
- [20] F. A. Al-Fahaidy, B. Al-Fuhaidi, I. AL-Darouby, F. AL-Abady, M. AL-Qadry, and A. AL-Gamal, "A diagnostic model of breast cancer based on digital mammogram images using machine learning techniques," *Applied Computational Intelligence and Soft Computing*, vol. 2022, no. 1, p. 3895976, 2022.
- [21] Eitan Sharon, Meirav Galun, Dahlia Sharon, Ronen Basri, and Achi Brandt, "Hierarchy and adaptivity in segmenting visual scenes," *Nature*, Vol. 442(7104): 719-846, 2006.