

Diz MR Görüntülerinde Yönelimli Gradyan Histogramları Kullanılarak Menisküs Yırtık Sınıflandırması

Meniscus Tear Classification Using Histogram of Oriented Gradients in Knee MR Images

¹Ahmet SAYGILI

Bilgisayar Mühendisliği Bölümü,
Namık Kemal Üniversitesi, Tekirdağ, Türkiye
asaygili@nku.edu.tr

²Songül ALBAYRAK

Bilgisayar Mühendisliği Bölümü,
Yıldız Teknik Üniversitesi, İstanbul, Türkiye
songul@ce.yildiz.edu.tr

Özetçe— Medikal görüntülerde otomatik bölütleme ve sınıflandırma çalışmaları son yıllarda yoğun olarak çalışılmaktadır. Elde edilen sonuçlar tıp uzmanlarının kararlarında destek olacak niteliktedir. Yapılan bu çalışmada da bulanık kümeleme yaklaşımları ile bölütlenmiş diz MR görüntülerine yönelimli gradyan histogramları (YGH) yöntemi uygulanarak öznelikler elde edilmiş ve elde edilen bu öznelikler farklı sınıflandırıcılar ile eğitilerek otomatik menisküs yırtık tespiti gerçekleştirilmiştir. Bu otomatik tespit işlemi için Osteoartrite Girişimi tarafından sağlanmış 28 farklı MR görüntüsü kullanılmıştır. Çalışmada özellikle YGH'nin etkileri detaylı olarak incelenmiştir. Sınıflandırma aşamasında destek vektör makineleri, aşırı öğrenme makineleri ve en yakın k-komşuluğu sınıflandırıcıları kullanılmıştır. Çalışmamızda %88.78'lik bir oran ile destek vektör makineleri en başarılı sınıflandırıcı olmuştur. İlerleyen çalışmalarda farklı öznelik çıkarımı ve bölütleme yöntemleri ile sistemin başarısının artırılması hedeflenmektedir.

Anahtar Kelimeler — Menisküs yırtıkları, Bölütleme, Sınıflandırma, Medikal Görüntü İşleme, Yönelimli Gradyan Histogramları

Abstract— Automatic segmentation and classification studies in medical images have been intensely studied in recent years. The results obtained will support the decisions of medical experts. In this study, features were obtained by applying histogram of oriented gradients (HOG) method to segmented knee MR images with fuzzy clustering approaches and these features were trained with different classifiers to perform automatic meniscus tear detection. For this automatic detection, 28 different MR images provided by the Osteoarthritis Initiative were used. In particular, the effects of HOG have been studied in detail. Support vector machines, extreme learning machines, and k-nearest neighbor classifiers have been used in the classification stage. The support vector machines became the most successful classifier with a success rate of 88.78%. It is aimed to increase the success of the system with different feature extraction and segmentation methods in the following studies.

Keywords — Meniscus tears, Segmentation, Classification, Medical Image Processing, Histogram of Oriented Gradients

I. GİRİŞ

Medikal alanda gerçekleştirilen işlemlerde erken tanı ve tedavinin önemi yadsınmaz bir gerçektir [1]. Bu sebeple erken tanı ve tedaviye destek olabilecek otomatik sistemler gitgide önem kazanmaktadır. Tıbbi görüntüler üzerindeki anomalilerin tespitinde bölütleme işlemi önemli bir yer tutmaktadır. Bölütleme görüntü üzerindeki farklı nesnelere birbirinden ayırt edilebilmesini sağlamaktadır. Bu yüzden bölütleme yöntemleri görüntü işlemede görüntüler üzerindeki farklı nesnelere tespitinde ve yerlerinin belirlenmesinde sıklıkla kullanılmaktadır. Tıbbi görüntüleme en sık tercih edilen görüntüleme yöntemlerinden birisi Manyetik rezonans (MR) görüntülemesidir. Gerçekleştirdiğimiz çalışmada da Osteoartrite girişimi tarafından halka erişimi açık olan ve MR görüntülerinden oluşan veri seti kullanılmıştır [2].

Çalışmamız da bölütleme aşamasında bulanık kümeleme yöntemlerinden faydalanılmıştır. Kümeleme nesnelere belirli özneliklerine göre gruplama işlemine verilen isimdir. Aynı kümede olan örnekler birbirine benzerken farklı kümelerde ki örnekler daha az benzer olmaktadır. Bulanık c-ortalama (BCO) yöntemi sıklıkla tercih edilen bir bölütleme yöntemidir [3]. Bir görüntünün üzerindeki pikseller yüksek derecede ilintiye sahiptir; diğer bir deyişle, yakın çevredeki pikseller, neredeyse aynı öznelik verisine sahiptir. Bu nedenle, komşu piksellerin mekansal ilişkisi, görüntü bölütlemeye yardımcı olabilecek önemli bir özneliktir. Genel sınır tespit teknikleri, görüntü bölütlemesi için bu mekansal bilgiden faydalanmıştır. Bununla birlikte, BCO algoritması bu uzamsal bilgiyi tam olarak kullanmamaktadır. Standart bir BCO tekniğinde, görüntü bir piksel, anormal öznelik verisi nedeniyle yanlış bir şekilde sınıflandırılır. Mekansal BCO'da (MBCO) ise komşu piksellerin küme dağılımı değerlendirildikten sonra her kümenin üyelik ağırlıkları değiştirilmektedir [4]. Bu durum, görüntünün etkisini büyük ölçüde azaltır ve algoritmayı

homojen kümelenmeye yönlendirir. Bu sebeple çalışmamız da bölütleme işlemi için MBCO yöntemi kullanılmıştır.


Görüntü işlemede birçok öznelik çıkarım yöntemi mevcuttur. Ancak bazı yöntemler birçok farklı problemin çözümünde başarılı bir şekilde uygulanmaktadır. Yönelimli gradyan histogramları (YGH) [5] yöntemi öznelik çıkarım işleminde farklı tanımlayıcı sistemlerde başarılı sonuçlar vermiş bir yöntemdir. Bu yöntemin medikal görüntü işleme [6], parmak izi tanıma [7], insan tespiti [5] ve yüz tanıma [8] gibi birçok alanda başarılı bir şekilde uygulandığı görülmektedir.

Çalışmamızın ikinci bölümünde diz MR görüntülerinde menisküs yapıları, üçüncü bölümde çalışmada kullanılan yöntem, dördüncü bölümde deneysel çalışmalar ve son bölümde sonuçlara yer verilmiştir.


II. DİZ MR GÖRÜNTÜLERİNDE MENİSKÜS YAPILARI

Menisküs yapıları Şekil 1'den de görüldüğü üzere diz ekleminde kaval ve uyluk kemikleri arasında yer alan kıkırdak yapılarıdır [9]. Dizin üzerine yapılan yükün taşınmasında görevli olan menisküsler her diz ekleminde iki adetdir. Birisi dizin iç kısmında yer alan iç menisküs, diğeri de dizin dış kısmında yer alan dış menisküstür.

Diz ekleminde en sık ortaya çıkan rahatsızlıklardan bir tanesi menisküs yırtıklarıdır. Menisküs yırtıkları genellikle diz bükülürken veya ani dönme hareketi denilen hareketle oluşur. Menisküs yırtıkları ağır kaldırıldığında veya spor yaparken ortaya çıkabilir. Yaşlandıkça menisküs aşınır ve bu daha kolay menisküs yırtığı oluşmasına neden olur [10].



Şekil 1. Diz ekleminin detaylı gösterimi [11]



Şekil 2. En yaygın menisküs yırtık tipleri [12]

Menisküs yırtıklarında, yırtığın tipi belirtilerin oluşmasında etkilidir [13]. Menisküs yırtık tipleri yırtığın şekline, konumuna ve boyutuna göre çeşitlenmektedir. Literatürde yer alan çalışmalarda şekillerine göre menisküs yırtıkları için en sık kullanılan yırtık tipleri Şekil 2'de görülmektedir. Şeklin üst kısmında görülen yırtık tiplerinin ilerlemesi sonucunda alt kısmında ok ile gösterilen yırtık tipleri ortaya çıkmaktadır.

III. YÖNTEM

Çalışmamızda minimum menisküs çerçevelerinin üzerinden öncelikle MBCO yöntemi ile menisküs yapılarının bölütlenmesi işlemi gerçekleştirilmiştir. MBCO'da mekansal bilgiden faydalanmak için mekansal işlev 1'e göre tanımlanır;

$$h_{ij} = \sum_{k \in NB(x_j)} u_{ik} \quad (1)$$

Burada $NB(x_j)$, merkezi x_j pikseli olan bir kare pencereyi, u 'da üyelik fonksiyonunu temsil eder. Çalışmamızda 5x5 piksel boyutunda bir kare pencere kullanılmıştır. Üyelik fonksiyonu gibi mekansal fonksiyon h_{ij} , x_j pikselinin i 'inci kümeye ait olma ihtimalini temsil eder. Bir pikselin bir kümedeki mekansal fonksiyonu, komşularının çoğunluğu aynı kümelere aitse büyüktür. Mekansal fonksiyon üyelik fonksiyonuna şu şekilde dahil edilmiştir:

$$u'_{ij} = \frac{u_{ij}^p h_{ij}^q}{\sum_{k=1}^c u_{kj}^p h_{kj}^q}, \quad (2)$$

Burada p ve q , her iki fonksiyonun (üyelik ve mekansal) görece önemini kontrol etmek için kullanılan parametrelerdir. Homojen bir bölgede, mekansal fonksiyonlar orijinal üyeliği güçlendirir ve kümeleme sonucu değişmeden kalır. Bununla birlikte, gürültülü bir piksel için, bu formül, gürültülü bir kümenin, komşu piksellerin etiketleriyle ağırlığını azaltır. Sonuç olarak, gürültülü bölgelerdeki yanlış sınıflandırılmış pikseller kolayca düzeltilebilir.

Bölütlenmiş olan menisküs yapılarına YGH uygulanarak öznelikler elde edilmiştir. YGH nesne ve görüntü tanımda başarılı sonuçlar veren bir tanımlayıcı çıkarım yöntemidir. YGH yönteminde piksellerin gradyan değerleri ve yönelim açılarıyla öznelik çıkarımı gerçekleştirir. Temel amaç, görüntüyü yerel histogramlar şeklinde temsil etmektir [5]. Bu yönüyle ölçekten bağımsız öznelik dönüşümü (Scale-invariant feature transform (SIFT)) [14] ve hızlandırılmış sağlam öznelikler (Speeded-up robust features (SURF)) [15] yöntemleri ile benzerlik göstermektedir. Ancak YGH örtüşen bloklar kullanması ve yerel parlaklık normalizasyonu gibi özellikleri sayesinde bu yöntemlerden daha başarılı bir tanımlayıcıdır. YGH yönteminde uygulanan algoritmanın işlem adımları şu şekildedir;

- 1) Giriş görüntüsünün daha küçük boyutlarda alt görüntülere bölünmesi: "hücreler"
 - a) Hücreler problemin türüne göre karesel (R-YGH) veya dairesel (C-YGH) seçilebilir.
- 2) Her bir hücre için gradyan büyüklüklerinin (G) ve gradyan yönlendirme açılarının (θ) hesaplanması
- 3) Her piksel için hesaplanan gradyan büyüklüklerinin hücrelerin gradyan histogramlarının hesabı için kullanılması

- Her bir pikselin gradyan büyüklüğüne karşılık gelen gradyan yönlendirme açısına göre kanallara (bin) ayırma işleminin gerçekleştirilmesi
 - 0-180 derecelik işaretli gradyanların seçilmesi durumunda histogramın 20 derecelik aralıklardan oluşan 9 kanala ayrılması (0, 20, 40, ..., 160).
 - Gradyan yönlendirme açısının değerine göre gradyan büyüklüklerinin kanallara aktarılması.
- 4) Elde edilen sonuçların aydınlatma koşullarından etkilenmesini önlemek için blok normalleştirilmesinin gerçekleştirilmesi.
- 5) YGH öznelik vektörlerinin elde edilmesi


YGH özneliklerini çıkarmak için öncelikle gradyan (yön vektörü) büyüklüğü ve gradyan yönlendirme açısı hesaplanır. Bunun için, G_x ve G_y kenarları görüntüye (I) yatay ve dikey Sobel [16] filtreleri uygulanarak belirlenir (3). Ardından, gradyan büyüklüğü ve gradyan yönlendirme açısı (G ve θ) 4'te görüldüğü gibi hesaplanır.

$$G_x = I * [-1 \ 0 \ 1], \quad G_y = I * [-1 \ 0 \ 1]^T \quad (3)$$

$$G = \sqrt{G_x^2 + G_y^2}, \quad \theta = \arctan \frac{G_x}{G_y} \quad (4)$$

Burada hesaplanmış olan açı (θ) gradyan histogramlarında girdi değeri olarak kullanılmaktadır. Dalal ve Triggs yaptıkları çalışmada işaretli 0-180 derece arasında 9 kanallı (bin) histogram oluşturmanın daha iyi sonuçlar verdiğini ortaya koymuşlardır [5]. Burada her bir pikselin gradyan büyüklüğüne karşılık gelen gradyan yönlendirme açısına göre 9 farklı kanala ayırma işlemi gerçekleştirilmektedir. Örnek bir ayırma işlemi Şekil 3'te görülmektedir.


YGH yönteminde görüntüler üzerindeki zıtlık etkisinin azaltılması ve ışık aydınlatması etkisinin minimuma indirilmesi için gradyan büyüklüklerinde normalleştirme işlemi gerçekleştirilir. Bu normalleştirme işleminde Şekil 4'te görüldüğü gibi hücreler bir araya getirilerek bloklar oluşturulur. Şekil 4'te mavi çerçeve ile görülen ve 4 hücrenin birleştirilmesi ile oluşturulan 2×2 'lik bir blok görülmektedir. YGH tanımlayıcıları elde edilirken bir önceki blokla bir sonraki bloğun üst üste örtüşürülerek keşilmesi sağlanır (Şekil 4'te sarı ve mavi bloklarda olduğu gibi).



Şekil 3. Gradyan (Yön Vektörü) Histogramlarının oluşturulması

YGH'nin ışık aydınlatması ve gölgelerden kaynaklanan değişimlere karşı gürbüz bir yöntem olmasını sağlayan işlem blok normalleştirme işlemidir. Bu işlemde her hücredeki piksel değerlerinin ortalaması alınarak hücrelerden oluşan bloklara uygulanır. Blok normalleştirme için uygulanan 3 yöntem

bulunmaktadır. v her bir bloktaki tüm histogramları içeren normalleştirilmemiş değerleri göstermek ve ϵ 'de bir sabit olmak üzere normalleştirme fonksiyonları Bağlantı 5, 6 ve 7'deki şekilde tanımlanmaktadır.



Şekil 4. Tanımlayıcı bloklarının oluşturulması

$$L1 - norm: v \rightarrow v / (\|v\|_1 + \epsilon) \quad (5)$$


$$L2 - norm: v \rightarrow v / \sqrt{(\|v\|_2^2 + \epsilon^2)} \quad (6)$$

$$L1 - sqrt: v \rightarrow \sqrt{v / (\|v\|_1 + \epsilon)} \quad (7)$$

Dalal ve Triggs yaptıkları çalışmada L2-norm ile normalleştirme yapmanın daha iyi sonuçlar verdiğini söylemektedirler [5]. Bu sebeple bizim çalışmamızda da L2-norm kullanılmıştır. YGH ile öznelikler elde edildikten sonra veri setinin %60'ı eğitim, %40'ı test için ayrılmıştır. Özneliklerin modellenmesi için en yakın k-komşuluğu (eYKK), destek vektör makineleri (DVM) ve aşırı öğrenme makineleri (AÖM) kullanılmıştır.

IV. DENEYSEL ÇALIŞMALAR

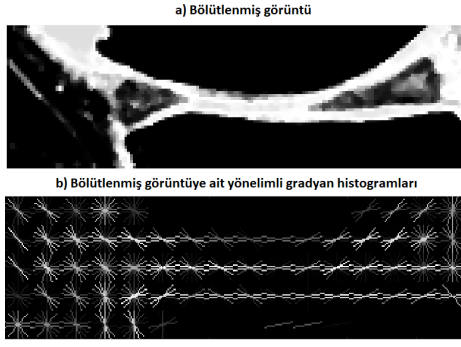
Çalışmamızda minimum menisküs pencerelerine öncelikle bölütleme işlemi uygulanmıştır. MR kesit görüntülerinden minimum menisküs pencerelerinin nasıl elde edildiğini görmek için önceki çalışmalar incelenebilir [17-19]. Bölütlemeye önce şekilde görüldüğü gibi ilk olarak ortanca filtresi [20] ile gürültü azaltılması ve ardından kontrast artırımı işlemleri uygulanmıştır. Bu işlemlerin ardından MBCO yöntemi ile bölütleme işlemi uygulanmıştır. Gerçekleştirilen bu işlemlerin sonuçlarında elde edilen bölütlenmiş görüntüler Şekil 5'te görülmektedir. Küme merkezleri yardımıyla menisküslerin yer aldığı bölütlenmiş görüntü seçilmiş ve ardından bu görüntü üzerinden öznelik çıkarımı gerçekleştirilmiştir.



Şekil 5. MBCO yöntemi ile bölütleme işlem adımları

YGH öznelikleri çıkartılırken farklı hücre büyüklüğü (cell size) parametreleri deneysel çalışmalar sonucunda kullanılan pencere boyutlarına ve bellek miktarına göre 10 olarak belirlenmiştir. Bu, x ve y yönlerinde pencerenin 10×10 'luk hücrelere bölündüğü ve her bir hücre için tanımlayıcıların hesaplandığı anlamına gelmektedir. Hücre büyüklüğünün 10 seçilmesi neticesinde elde edilen YGH'ye ait bir örnek Şekil 6'da görülmektedir.

Elde edilen YGH öznelikleri ile sistem modellenmiş ve eYKK, DVM ve AÖM sınıflandırıcıları ile sınıflandırma işlemi gerçekleştirilmiştir. Tablo 1'den görüldüğü üzere menisküs yırtık tespiti için en başarılı sınıflandırıcı %88.78 başarı oranı ile DVM olmuştur.



Şekil 6. Menisküs dokusuna ait yönelimli gradyan histogramlarının görselleştirilmesi

Tablo 1. Sınıflandırma sonuçları

	eYKK	DVM	AÖM
Doğruluk (%)	81.89	88.78	84.44
Duyarlılık (%)	88.35	92.23	87.14
Özgüllük (%)	74.73	84.95	81.45

DVM yöntemi ile elde edilmiş sonuçlara ait karışıklık matrisi Tablo 2'de görülmektedir. Tablodan 28 MR görüntüsünde yer alan toplam 392 kesit görüntüsü için elde edilen yırtık ve sağlıklı menisküslere ait hatalı ve doğru sınıflandırma sayılarını görmek mümkündür.

Tablo 2. Sınıf karışıklık matrisi

		Gerçek	
		Sağlıklı	Yırtık
Tahmin	Sağlıklı	190	28
	Yırtık	16	158

V. SONUÇ VE DEĞERLENDİRME

Bu çalışmada medikal görüntüleme sıklıkla kullanılan MR görüntülerini kullanarak menisküslerin yırtık olup olmadıklarını tespit edebilen bir otomatik teşhis sistemi önerilmiştir. Yapılan çalışma sayesinde radyoloji ve ortopedi doktoralarının kararlarında yardımcı olabilecek bir karar destek sistemi oluşturulmuştur. Toplamda 28 farklı MR görüntüsü ile gerçekleştirilen bu çalışmada bölütleme aşamasında MBCO kümeleme yöntemi kullanılmıştır. Elde edilen bölütlenmiş görüntülere YGH öznelik çıkarma yöntemi uygulanmış ve öznelik çıkarımının etkileri yöntem bölümünde verilmiştir. Makine öğrenmesinde sıklıkla kullanılan sınıflandırma yöntemleri ile öznelikler modellenmiş ve en yüksek doğruluk oranı DVM yöntemi ile %88.78 seviyelerinde olmuştur. İlerleyen çalışmalarda farklı öznelik çıkarımı ve bölütleme yöntemleri kullanılarak karşılaştırmalı değerlendirmeler yapılması hedeflenmektedir.

BİLGİLENDİRME

OAI, National Institutes of Health (NIH) sermayesiyle beş sözleşmeden (N01-AR-2-2258; N01-AR-2-2259; N01-AR-2-2260; N01-AR-2-2261; N01-AR-2-2262) oluşan bir kamu-özel

ortaklığıdır. Özel sermaye ortakları arasında Novartis şirketi, Merck Araştırma Laboratuvarları, GlaxoSmithKline ve Pfizer A.Ş. bulunmaktadır. OAI'nin kamu kullanımına açık veri setini kullanarak hazırlanan bu metin OAI araştırmacılarının, NIH'in veya özel sermaye ortaklarının fikir ya da görüşlerini yansıtmamaktadır. Kamu kullanımına açık olan bu veri setini sağlayan kuruluşlara teşekkürlerimizi sunarız.

Ayrıca bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK-Proje Numarası: 116E151) tarafından desteklenmiştir.

KAYNAKÇA

- [1] M. E. Bowers, G. A. Tung, B. C. Fleming, J. J. Crisco, and J. Rey, "QUANTIFICATION OF MENISCAL VOLUME BY SEGMENTATION OF 3T MAGNETIC RESONANCE IMAGES," *Journal of biomechanics*, vol. 40, pp. 2811-2815, 03/27 2007.
- [2] M. Nevitt, D. Felson, and G. Lester, "The osteoarthritis initiative," in *Protocol for the Cohort Study*, ed. 2009
- [3] J. C. Bezdek, R. Ehrlich, and W. Full, "FCM: The fuzzy c-means clustering algorithm," *Computers & Geosciences*, vol. 10, pp. 191-203, 1984/01/01 1984.
- [4] K.-S. Chuang, H.-L. Tzeng, S. Chen, J. Wu, and T.-J. Chen, "Fuzzy c-means clustering with spatial information for image segmentation," *computerized medical imaging and graphics*, vol. 30, pp. 9-15, 2006.
- [5] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2005, pp. 886-893 vol. 1.
- [6] D. Agarwal, K. S. Shriram, and N. Subramanian, "Automatic view classification of echocardiograms using Histogram of Oriented Gradients," in *2013 IEEE 10th International Symposium on Biomedical Imaging*, 2013, pp. 1368-1371.
- [7] C. Gottschlich, E. Marasco, A. Y. Yang, and B. Cukic, "Fingerprint liveness detection based on histograms of invariant gradients," in *IEEE International Joint Conference on Biometrics*, 2014, pp. 1-7.
- [8] O. Deniz, G. Bueno, J. Salido, and F. De la Torre, "Face recognition using histograms of oriented gradients," *Pattern Recognition Letters*, vol. 32, pp. 1598-1603, 2011.
- [9] P. Ghosh and T. K. Taylor, "The Knee Joint Meniscus: A Fibrocartilage of Some Distinction," *Clinical orthopaedics and related research*, vol. 224, pp. 52-63, 1987.
- [10] WebMD. *Knee Injury and Meniscus Tear*. Available: <http://www.webmd.com/fitness-exercise/tc/meniscus-tear-topic-overview#1>
- [11] H. Mysid. (2017). *Diz Eklemi Oluşturan Yapılar*. Available: <http://www.wikizero>.
- [12] J. T. Hansen, *Netter's Clinical Anatomy E-Book*: Elsevier Health Sciences, 2014.
- [13] S. Gökay. *Menisküs Zedelenmeleri*. Available: www.selimgokay.com/files/doc/meniskus.pdf
- [14] D. G. Lowe, "Object recognition from local scale-invariant features," in *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*, 1999, pp. 1150-1157.
- [15] H. Bay, T. Tuytelaars, and L. Van Gool, "Surf: Speeded up robust features," *Computer vision-ECCV 2006*, pp. 404-417, 2006.
- [16] I. Sobel, "An isotropic 3x3 image gradient operator," *Machine vision for three-dimensional scenes*, pp. 376-379, 1990.
- [17] A. Saygılı and S. Albayrak, "A new computer-based approach for fully automated segmentation of knee meniscus from magnetic resonance images," *Biocybernetics and Biomedical Engineering*, vol. 37, pp. 432-442, 2017.
- [18] A. Saygılı, H. Kaya, and S. Albayrak, "Automatic detection of meniscal area in the knee MR images," in *Signal Processing and Communication Application Conference (SIU), 2016 24th*, 2016, pp. 1337-1340.
- [19] A. Saygılı and S. Albayrak, "Meniscus segmentation and tear detection in the knee MR images by fuzzy c-means method," in *Signal Processing and Communications Applications Conference (SIU), 2017 25th*, 2017, pp. 1-4.
- [20] Z. Wang and D. Zhang, "Progressive switching median filter for the removal of impulse noise from highly corrupted images," *IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing*, vol. 46, pp. 78-80, 1999.