



## Otsu ve Rocchio Metotlarıyla Beyin Tümörü Tespiti

Rıfat Aşlıyan<sup>1\*</sup>

<sup>1\*</sup> Aydın Adnan Menderes Üniversitesi, Fen Fakültesi, Matematik Bölümü, Aydın, Türkiye, (ORCID: 0000-0003-1495-713X), [rasliyan@adu.edu.tr](mailto:rasliyan@adu.edu.tr)

(4th International Conference on Applied Engineering and Natural Sciences ICAENS 2022, November 10 - 13, 2022)

(DOI: 10.31590/ejosat.1200979)

**ATIF/REFERENCE:** Aşlıyan, R. (2022). Otsu ve Rocchio Metotlarıyla Beyin Tümörü Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (43), 69-74.

### Öz

Beynimiz, kafatası içinde bulunan ve merkezi sinir sisteminin en karmaşık organıdır. En karmaşık organımız olan beynimiz vücudumuzun tüm fonksiyonlarını kontrol eder. Beyin tümörleri, beyindeki hücrelerin kontrolsüz bir şekilde büyümesiyle ortaya çıkar. Beyin tümörlerini erken teşhis etmek genellikle daha fazla tedavi imkanı sağlar. Beyin tümörlerinin teşhisinde en çok manyetik rezonans görüntüleme kullanılır. Bu çalışmada, Otsu ve Rocchio metotları kullanılarak bölütleme sistemleri geliştirildi. Beyin MR görüntüsünü girdi olarak alan, kafatası ayırma, ön-işleme, segmentasyon ve art-işleme işlemlerini gerçekleştiren sistemler tasarlandı ve uygulandı. Ön-işlemeden önce, kafatası bölgesi beyin MR görüntü veri setindeki görüntülerden çıkarılır. Ön-işlemede çeşitli filtreleme ve morfolojik tekniklerle beyin görüntülerinin kalitesi artırılır ve görüntülerin gürültüsü ortadan kaldırılır. Bölütlemeye ise Otsu metodu ile eşik değerlerinin belirlenmesi ile beyindeki tümürlü bölge tespit edilir. Art-işlemede, beyin tümörü veri setinin eğitim veri seti kullanılarak Rocchio sınıflandırıcı metodu eğitilir ve belirlenen tümürlü bölgelerin en uygun olanı bulunur. Böylece en doğru tümürlü bölge tespit edilerek optimize edilmiş olur. Test safhasında, sistemlerin başarılarını değerlendirmek amacıyla doğruluk, kesinlik ve seçicilik metrikleriyle sistemlerin başarıları karşılaştırılmıştır. Art-işleme sonucunda başarının önemli ölçüde arttığı görülmüştür.

**Anahtar Kelimeler:** Beyin Tümörü Bölütleme, Tıbbi Görüntüleme, Beyin MR Görüntüsü, Otsu Metodu, Rocchio Metodu.

## Brain Tumour Detection with Otsu and Rocchio Methods

### Abstract

Our brain is the most complicated organ of the central nervous system, located inside the skull. Our most complex organ, our brain, controls all the functions of our body. Brain tumours occur when cells in the brain grow uncontrollably. Detecting brain tumours early usually provides more treatment opportunities. Magnetic resonance imaging is mostly used in the diagnosis of brain tumours. In this study, segmentation systems were developed using Otsu and Rocchio methods. Systems that take brain MR images as input and perform skull separation, pre-processing, segmentation and post-processing have been designed and implemented. Before pre-processing, the skull region is extracted from the images in the brain MR image dataset. In pre-processing, the quality of brain images is improved and the noise of the images is eliminated by various filtering and morphological techniques. In segmentation, the tumour region in the brain is determined by detecting the threshold values with the Otsu method. In post-processing, the Rocchio classifier method is trained using the training dataset of the brain tumour dataset and the most suitable one of the determined tumour regions is found. Thus, the most accurate tumour region is detected and optimized. In the test phase, the success of the systems was compared with the accuracy, precision and selectivity metrics to evaluate the success of the systems. As a result of post-processing, it was observed that success of the system is increased significantly.

**Keywords:** Brain Tumor Segmentation, Medical Imaging, Brain MRI Image, Otsu Method, Rocchio Method.

\* Sorumlu Yazar: [rasliyan@adu.edu.tr](mailto:rasliyan@adu.edu.tr)

## 1. Giriş

Beyin tümörleri, beyin hücrelerinin büyümesi, vücut tarafından kontrol edilemeyen, aşırı büyüyen hücrelerden oluşur. Beyin tümörlerindeki hücre artışı kontrol dışıdır. Genel olarak, tümörler iyi huylu veya kötü huylu tümörler şeklinde sınıflandırılır. Beyin hücreleri kafatası içinde bulunur. Kafatası ise, hareketli eklemleri olmayan bir kemik yapısıdır. Bu sebeple, kafatası genişleyemez ve beyin tümörü, beyin içinde oluştuktan sonra genişleyerek beyin hücrelerine baskı yapar.

Beyin tümörleri ilk olarak beyin içinde oluşmuşsa bu tip beyin tümörlerine birincil beyin tümörleri adı verilir. Fakat, kanser hücreleri vücudun diğer bölgelerinde meydana gelip beyne de yayılmışsa bu tip tümörler, ikincil veya metastatik tümör olarak isimlendirilir. Beyin tümörleri beyinde farklı hızlarda yayılabilir. Büyüme hızı, beyin tümörünün konumuna bağlıdır. Tümörün yeri de insan sinir sistemine zarar vermesi bakımından çok önemlidir. Aynı zamanda, tümörün tedavisi, tümörün büyüklüğüne, bulunduğu yere ve tipine bağlıdır. Beyin tümörlerinin teşhisi, hastanın rahatsızlıkları ve şikayetleri ile başlar. Devamında doktorlar hastaların reflekslerinin, güçlerinin, duyularının, dengelerinin ve sinirlerinin ne kadar iyi olduğunu araştırırlar. Doktorlar, tümör olduğundan şüphelenirlerse beyin tümörlerini tespit etmek için MR çekirmek gibi farklı tetkikler yaparlar.

Bir beyin tümörünün kesin teşhisi genellikle manyetik rezonans görüntüleme ile başlar. Beyindeki tümör belirlendikten sonra yaygın olarak yapılan işlem, biyopsi veya ameliyatla beyin tümörünün tipine karar vermektir. Yani, beyin tümörünün bir parçası alınıp ve uzmanlar tarafından incelenerek ne tip tümör olduğu belirlenir.

Beyin tümörleri farklı görüntüleme yöntemleri ile görüntülenmektedir. Başlıca görüntüleme yöntemleri CBT (Bilgisayarlı Beyin Tomografisi), MRI (Manyetik Rezonans Görüntüleme), PET Taraması (Pozitron Emisyon Tomografisi) ve SPECT'tir (Tek Foton Emisyon Bilgisayarlı Tomografi).

Medikal görüntü işlemede, beyin tümörünün bölütlenmesi, yani beyin MR görüntüsündeki tümörlerin bölütlere ayrılması, yerlerinin belirlenmesi hem doktorlara hem de hastalara çok büyük fayda sağlayacaktır. Çok daha kısa zamanda ve doğru tanının konulmasına sebep olacaktır.

Beyin tümörü tespitinde ve bölütlenmesinde farklı sınıflandırma ve bölütleme metotları kullanan çalışmalar yapılmıştır. Bu çalışmaların bazılarında Otsu metodu (AlAzawee, 1995; Karaddi, v.d., 2018; Aşlıyan ve Atbakan, 2020), K-ortalamlar (Batista ve Kitney, 1995; Wu, M, v.d., 2007; Juang ve Wu, 2010), destek vektör makineleri (Zhang v.d., 2004; Ayachi ve Amor, 2009), kendi kendini düzenleyen haritalar (SOM) (Dharshini ve Hemanandhini, 2016; Saraswathi v.d., 2019), yapay sinir ağı bulanık çıkarım sistemi (ANFIS) (Sharma ve Mukharjee, 2013; Kathirvel ve Batri, 2017), evrişimli sinir ağı (Pereira v.d., 2016), bulanık C-ortalamlar (Prakash ve Kumari, 2016), ve genetik algoritmalar (Ali v.d., 2013) kullanılmıştır.

Beyin tümörü bölütlemenin genel yapısında, beyin tümörü MR görüntüleri, bölütleme sistemine girdi olarak alınmaktadır. İlk olarak, kafatası ayırma safhasında kafatası tespit edilerek görüntüdeki kafatası çıkarılır. Daha sonra ön-işleme safhasında, beyin görüntüde kalan kısmına Gaussian ve Wiener filtreleri gibi bazı gürültü azaltma filtreleme yöntemleri uygulanmaktadır. Devamında, Otsu yöntemi ile bölütleme işlemi yapılır. En son

olarak art-işleme safhasında bölütlenerek elde edilen beyin tümörü görüntüsü iyileştirilerek bölütleme başarısı artırılmıştır. Art-işleme safhasında Rocchio metodu kullanıldı. Bu metot ile eğitim veri setindeki tümürlü bölgelerin özelliklerine göre Rocchio metodu ile eğitilir ve bir model oluşturulur. Test veri setindeki görüntülerle sistemin başarısı test edilir. Art-işleme işlemi sistemin başarısını artırdığı görülmüştür.

Bu çalışmada üç farklı sistem geliştirildi. İlk Kafatası ayırmadan yapılan bölütleme işlemidir. İkincisi, kafatasının ayırdıktan sonra yapılan bölütleme işlemi ve üçüncüsü ise hem kafatası ayrılmış ve sonrasında art-işleme uygulanmış sistemdir. Bu geliştirilen sistemlerin en başarılısı kafatası ayrılmış ve art-işleme uygulanmış sistemdir. Bu sistemlerin uygulanmasıyla başarı oranları olarak %96 doğruluk, %95 kesinlik ve %95 seçicilik sonuçları elde edilmiştir. Diğer segmentasyon yöntemlerinden daha başarılı olduğu görülmüştür.

Bu çalışmanın diğer bölümleri aşağıdaki gibi planlanmıştır. İkinci bölümde, Otsu yöntemi ve Rocchio metotlarının nasıl çalıştığı açıklanmıştır. Üçüncü bölümde, veri seti ve sistemin başarısını ölçen metrikler hakkında bilgiler verilmiştir. Aynı zamanda sistemin test sonuçları sunulmuş ve yöntemlerin başarısı değerlendirilmiştir. Çalışmanın ana noktaları sonuç bölümünde özetlenmiştir.

## 2. Materyal ve Metot

Bu çalışmada beyin MR görüntülerinin bölütlenmesi için Otsu yöntemi kullanıldı. Bölütleme işleminden sonra daha başarılı bölütlemeye ulaşmak için Rocchio sınıflandırıcı metodu ile art işleme yapılmıştır. Bu bölümde, Rocchio ve Otsu yöntemleri açıklanmıştır.

### 2.1. Rocchio Sınıflandırma Metodu

Rocchio (Hastie v.d., 2001; Park v.d., 2003) ya da diğer adıyla en yakın merkez sınıflandırma metodu basit ve hızlı bir sınıflandırma yöntemidir. Bu metot, yeni bir örneğin hangi sınıfa ait olduğunu bulmak için sınıfların merkezlerini sınıf olarak kabul ederek merkezlere olan uzaklıkları hesaplar ve verilen bir örnek vektörünü, en yakın uzaklığa sahip olan sınıf olarak sınıflandırır.

Denklem 1'de  $\mathbf{o}_{S_j}$ ,  $S_j$  sınıfının aritmetik ortalamasını ifade eden merkez vektördür.  $|S_j|$ , bu sınıfın örnek sayısıdır.  $\mathbf{x}_i$ 'ler ise eğitim veri setindeki  $S_j$  sınıfının örnekleridir. Bu örnekler ne kadar niteliğe sahipse o kadar elemana sahip vektörlerdir.

$$\mathbf{o}_{S_j} = \left( \sum_{\mathbf{x}_i \in S_j} \mathbf{x}_i \right) / |S_j| \quad (1)$$

Denklem 1'deki gibi diğer sınıfları da temsil edecek diğer prototip vektörler de elde edilir. Sınıflandırma gerçekleştirirken hangi sınıfta ait olduğu bilinmeyen bir örnek  $\mathbf{x}$  vektörünün sınıfını belirlemek için Denklem 2 kullanılır.

$$S(x) = \underset{S_j}{\operatorname{argmin}} d(\mathbf{x}, \mathbf{o}_{S_j}) \quad (2)$$

$d(\mathbf{x}, \mathbf{o}_{S_j})$ ,  $\mathbf{x}$  ve  $\mathbf{o}_{S_j}$  vektörleri arasındaki uzaklığı temsil etmektedir.

Rocchio sınıflandırıcı, bu çalışmada art-işleme aşamasında kullanılmıştır. Eğitim veri setindeki örnekler üç öznitelikten yani tümör bölgesinin alanı, çembersellik ve eksantrik durumunu belirten değerlerden oluşan vektörler ile temsil edilir. Bu örneklerin merkez vektörleri hesaplanır.

K-en yakın komşudan farklı olarak sınıfı belli olmayan bir örneği sınıflandırmak için sadece her sınıfın merkez vektörleriyle uzaklıklarını hesaplamak ve en yakın yani en çok benzeyen sınıfı bulmak yeterlidir. Fakat, K-en yakın komşu metodunda sınıfın her örneğiyle uzaklıkların hesaplanması ve en küçük uzaklığın bulunması gerekir. Bu da çalışma zamanı karmaşıklığını artıracaktır. Rocchio metodunda çalışma zamanı karmaşıklığı doğrusaldır yani  $O(n)$ 'dir.

Uzaklıkların hesaplanmasında farklı uzaklık ölçüleri kullanılabilir. Bu çalışmada Öklid uzaklık ölçüsü tercih edilmiştir. Denklem 3'te  $\mathbf{x}$  ve  $\mathbf{y}$  örnek vektörlerinin Öklid uzaklığına göre nasıl hesaplandığını göstermektedir. Burda özniteliklerin sayısı  $k$  ile belirtilmektedir.

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3)$$

## 2.2. Otsu Metodu

Otsu metodu (AlAzawee, 1995; Karaddi, v.d., 2018; Aşlıyan ve Atbakan, 2020), bilgisayarla görü, görüntü analizi ve işlemede sıklıkla kullanılan adaptif bir eşikleme yöntemidir. Genellikle, girdi olarak alınan gri-tonlamalı görüntüler, eşik değerler belirlenerek bölütleme yapılır ya da siyah-beyaz görüntüye dönüştürülür. Yani, Otsu metodu, buradaki uygun eşik değerlerinin elde edilmesinde kullanılır. Bu eşik değerleri farklı sınıflardaki görüntü piksellerin ayırt edilmesinde belirleyici olmaktadır. Uygun eşik değerleri, sınıf içi piksel değerlerin varyansını en aza indirerek ve sınıflar arası piksel değerlerinin en çok artırarak belirlenmektedir.

Sınıf içi varyansı en aza indirmek için, iki sınıf için ağırlıklı bir varyans toplamı tanımlanır.

Sınıflar arası varyans, Denklem 4'te gösterildiği gibi hesaplanır ve optimal eşik değerini bulmak için maksimize edilir.

$$\sigma^2(t) = w_b(t)w_f(t)[\mu_b(t) - \mu_f(t)]^2 \quad (4)$$

Denklem 5 ve 6'da nasıl hesaplandığı gösterilen  $w_b$  ve  $w_f$  ağırlıkları,  $t$  eşik değeri ile ikiye bölünen görüntünün sırasıyla ön ve arka plan kısımlarının olasılıklarını ifade etmektedir.

Bu olasılık değerleri, görüntünün histogramı bulunduğundan sonra hesaplanır. Görüntü histogramı, görüntüdeki bütün piksel değerlerinin toplam sayılarını yani piksel yoğunluğunu gösteren grafik olarak ifade edilebilir. Denklem 7 ve 8'de gösterildiği gibi  $\mu_b(t)$  ve  $\mu_f(t)$ , görüntülerin sırasıyla ön ve arka plan kısımlarının ortalamalarını temsil etmektedir.

$$w_b(t) = \sum_{i=0}^{t-1} p(i) \quad (5)$$

$$w_f(t) = \sum_{i=t}^{B-1} p(i) \quad (6)$$

$$\mu_b(t) = \frac{\sum_{i=0}^{t-1} i p(i)}{w_b(t)} \quad (7)$$

$$\mu_f(t) = \frac{\sum_{i=t}^{B-1} i p(i)}{w_f(t)} \quad (8)$$


Otsu Algoritması:

1. Gri-tonlamalı görüntü alınır.
2. Gri-tonlamalı görüntünün histogramı hesaplanır.

3. Görüntünün piksel yoğunluk olasılıkları bulunur.
4.  $w_b(0)$ ,  $w_f(0)$ ,  $\mu_b(0)$  ve  $\mu_f(0)$  için başlangıç değerleri atanır.
5. Bütün eşik değerleri  $t=0$ 'dan en yüksek piksel yoğunluk değerine kadar aşağıdaki adımlar uygulanır.
6.  $w_b(t)$ ,  $w_f(t)$ ,  $\mu_b(t)$  ve  $\mu_f(t)$  değerleri güncellenir.
7.  $\sigma^2(t)$  hesaplanır.
8.  $\sigma^2(t)$ 'nin maksimum olduğu  $t$  eşik değeri belirlenir.

## 3. Araştırma Sonuçları ve Tartışma

Bu çalışmadaki beyin tümörü veri seti, bütünü tümör alanını içeren ve gri-tonlamalı (256x256) piksel içeren 107 görüntüden oluşmaktadır. Veri setinin %70'i eğitim veri seti olarak, geri kalan kısmı test veri seti olarak bölünmüştür. Veri seti (Brain Tumor Dataset, 2019) menenjiyom (meningioma), gliyom (glioma) ve hipofiz (pituitary) tümör olmak üzere üç çeşit beyin tümörü olan hastalardan alınan T1-ağırlıklı, kontrastlı görüntüleri içerir. Şekil 1'de veri setindeki dört beyin MR görüntüsü verilmiştir.



Şekil 1. Veri setindeki dört beyin tümörü görüntüsü

Beyin tümörü bölütleme sistemlerinin başarı oranları doğruluk, kesinlik ve seçicilik gibi metriklerle değerlendirilmiştir. Bu metrikler, Denklem 9, 10 ve 11'de gösterildiği gibi DP, DN, YP ve YN kullanılarak hesaplanmıştır.

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (9)$$

$$\text{Kesinlik} = \frac{DP}{DP + YP} \quad (10)$$


$$\text{Seçicilik} = \frac{DN}{DN + YP} \quad (11)$$

Denklem 9, 10 ve 11'de belirtilen DP (Doğru Pozitif), sistemin beyin görüntüsünün tümör alanını doğru olarak tanıdığı piksel sayısıdır. Ancak, DN (Doğru Negatif), sistemin tümör olmayan alanı doğru olarak tanıdığı piksel sayısını ifade eder. Aynı şekilde YP (Yanlış Pozitif), tümör olmayan alanı yanlış sınıflandıran piksel sayısıdır. Fakat, YN (Yanlış Negatif), tümör bölgesini yanlış sınıflandıran piksel sayısıdır.

Beyin tümörü bölütleme sistemlerinin kodları, Intel Core i7-4700HQ 2.40 GHz işlemci, 16 GB Ana bellek, 256 GB SSD, 2 TB Harddisk ve Windows 10 işletim sistemi özelliklerine sahip bilgisayarda, MATLAB ile yazılmıştır.


Şekil 2'nin ilk sütununda, beyin MR tümörü görüntüleri, veri setinden elde edilen gerçek görüntülerdir. İkinci sütunda beyin kafatası kısmının ayrıldığı görüntüler gösterilmektedir. Aynı zamanda, bu gri tonlamalı görüntüler, Gaussian ve Wiener gürültü azaltma filtresi ile filtrelenir. MR görüntüleri, bu filtrelerin konvolüsyonu ile yumuşatılır. Üçüncü sütundaki siyah-beyaz görüntülerin beyaz bölgeleri, MR görüntülerinin beyin tümörü bölgeleri olarak tespit edilir.

Şekil 3'te ilk sütunda beyin MR görüntülerin orijinal görüntüleri gösterilmektedir. İkinci sütunda ise kafatası ayrıldıktan sonra bölütleme yapılmış olduğundaki görüntülerdir. Üçüncü sütunda ise art-işleme aşamasında Rocchio sınıflandırıcı ile eğitilmiş modeller kullanılarak elde edilen görüntülerdir. Görüleceği üzere gürültü olarak ifade edebileceğimiz kısımlar ortadan kaldırılmış ve başarı artırılmıştır.



Şekil 2. Beyin MR görüntüleri a) Beyin MR görüntüleri b) Kafatası ayrılmış beyin MR görüntüleri

Şekil 4'te görüleceği gibi ilk olarak eğitim veri setindeki beyin tümörünün özelliklerini belirlemek için beyin tümörü bölgesini içeren görüntüler Rocchio sınıflandırıcı ile öznitelikleri kullanılarak bir model oluşturulur. Burada kullanılan öznitelikler tümör piksel alanı, tümör çembersellik ve eksantrik değerleridir. Sonrasında test veri setindeki görüntülerden kafatası kısmı ayrılmış ve ön-işlemede görüntü kontrast ayarlama, Wiener ve Gaussian gürültü azaltma filtreleri uygulanmıştır. Devamında Otsu metodu ile eşik değerleri belirlenerek bölütleme yapılmıştır. Asıl bu çalışmada yapılan en önemli çalışma art-işlemedir. Art-işlemeyle hatalı bölütleme kısımları ortadan kaldırılmıştır. Her bir bölütlenmiş kısım eğitilmiş model yardımıyla ne ölçüde tümör bölgesi olduğu belirlenir. Eğitilmiş modelle, en çok tümör bölgesine benzeyen kısım tümörlü bölge olarak tespit edilir. Böylece başarı artırılmış olur.



Şekil 3. Otsu bölütleme metodu ile elde edilen beyin MR görüntüleri a) Beyin MR görüntüleri b) Bölütlenmiş beyin MR görüntüleri c) Art-işleme uygulanmış görüntüler



Şekil 4. Beyin tümörü tespitinin genel yapısı

Tablo 1, beyin tümörü bölütlemeye kafatası ayırma işlemi yapılmadan Otsu bölütlemeyle gerçekleştirilen sistemin başarı oranları gösterilmektedir. Bu başarı oranları oldukça düşüktür. Fakat, Tablo 2'de görüldüğü gibi kafatası ayrıldıktan sonra Otsu metoduyla yapılan bölütleme işleminde başarı oranları yaklaşık %10 civarında artmıştır. Bununla birlikte bu sisteme art-işleme

safhasını dahil ettiğimizde başarı daha da artmıştır. Tablo 3, kafatası ayrılmış ve hem Otsu hem de art-işlemede Rocchio metodu uygulanmış sistemin başarı oranı gösterilmektedir. Ortalama %4 oranında başarıyı artırmıştır.

Tablo 1. Kafatası ayırma işlemi yapılmadan Otsu bölütlemeye gerçekleştirilen sistemin başarı oranları

Başarı Ölçüleri	Otsu Metodu Bölütleme
Doğruluk	%82
Kesinlik	%72
Seçicilik	%82

Tablo 2. Kafatası ayırma işleminden sonra Otsu bölütlemeye gerçekleştirilen sistemin başarı oranları

Başarı Ölçüleri	Kafatası Ayırma+Otsu Metodu Bölütleme
Doğruluk	%91
Kesinlik	%93
Seçicilik	%91

Tablo 3. Kafatası ayırma işleminden sonra Otsu bölütlemeye gerçekleştirilen sistemin başarı oranları

Başarı Ölçüleri	Kafatası Ayırma+Otsu Metodu Bölütleme+Rocchio Metodu
Doğruluk	%96
Kesinlik	%95
Seçicilik	%95

#### 4. Sonuç

Bu çalışmada, ilk olarak beyin tümörü veri seti eğitim ve test olmak üzere ikiye bölünmüş ve sistem, eğitim veri setinin örnekleri kullanılarak Rocchio metoduyla eğitilmiştir. Sonrasında test veri setindeki görüntüler Otsu metodu ile bölütlenmiştir. Kafatası ayrılmadan ve ayrıldıktan sonraki görüntüler bölütlenmiş ve doğruluk, kesinlik ve seçicilik başarı ölçülerine göre değerlendirilmiş ve başarıları karşılaştırılmıştır. Sistemin başarı oranı, kafatası ayrıldıktan sonra yaklaşık %10 artmıştır. Bununla birlikte art-işlemeli sistem uygulandığında %10'a ek olarak başarı oranları yaklaşık %4 daha yükselmiştir. Sistemin doğruluk, kesinlik ve seçicilik oranları sırasıyla %96, %95 ve %95 olmuştur. Sonraki çalışmalarda hem bölütleme hem de art-işleme aşamasında farklı metotlar kullanılarak çalışmalar yapılacaktır.

#### Kaynakça

- AlAzawee, W. S. (1995). Computer-Aided Brain Tumor Edge Extraction Using Morphological Operations. MSc Thesis, Western Michigan University, Kalamazoo, USA.
- Ali, S. M., Abood, L. K. & Abdoon, R. S. (2013). Brain tumor extraction in MRI images using clustering and morphological operations techniques. *Int J Geograph Inform Syst Appl Remote Sens*, vol. 4(1).
- Aşlıyan, R. & Atbakan, İ. (2020). Automatic Brain Tumor Segmentation with K-Means, Fuzzy C-Means, Self-Organizing Map and Otsu Methods. *Journal of Selcuk-Technic*, 267-281.
- Ayachi, R. & Amor, N. (2009). Brain tumor segmentation using support vector machines. *European Conference on Symbolic and Quantitative Approaches to Reasoning with Uncertainty*, 736-747.
- Batista, J. & Kitney, R. (1995). Extraction of tumors from MR images of the brain by texture and clustering. *Conference on Image Analysis and Processing*, 235-240.
- Brain Tumor Dataset. (2019) Website. [Online]. Available: [https://figshare.com/articles/brain\\_tumor\\_dataset/1512427](https://figshare.com/articles/brain_tumor_dataset/1512427).
- Dharshini, R. & Hemanandhini, S. (2016). Brain tumor segmentation based on Self Organising Map and Discrete Wavelet Transform. *International Conference on Computer Communication and Informatics (ICCCI)*, Coimbatore, India.
- Hastie, T., Tibshirani, R. & Friedman, J. (2001). *The Elements of Statistical Learning*. Springer Series in Statistics. Springer Verlag, New York.
- Juang, L. & Wu, M. (2010). MRI brain lesion image detection based on color-converted k-means clustering segmentation. *Measurement*, 43(7), 941-949.
- Karaddi, S., Babu, P. & Reddy, R. (2018). Detection of Brain Tumor Using Otsu-Region Based Method of Segmentation. *International Conference on Computing Methodologies and Communication (ICCMC)*, 128-134.
- Kathirvel, R. & Batri, K. (2017). Detection and diagnosis of meningioma brain tumor using ANFIS classifier. *Imaging Syst Technol*, 27, 187-192.
- Park, H., Jeonand, M. & Rosen, J. B. (2003). Lower dimensional representation of text data based on centroids and least squares. *BIT*, 43(2), 1-22.
- Pereira, S., Pinto, A., Alves, V. and Silva, C. A. (2016). Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans Med Imag*, 35, 1240-1251.
- Prakash, R. M. & Kumari, R. S. S. (2016). Fuzzy C means integrated with spatial information and contrast enhancement for segmentation of MR brain images. *Int J Imag Sys Technol.*, 26, 116-123.
- Saraswathi, D., Priya, B. L. & Lakshmi, R. P. (2019). Brain Tumor Segmentation and Classification using Self Organizing Map. *International Conference on System, Computation, Automation and Networking (ICSCAN)*, Pondicherry, India.
- Sharma, M. & Mukharjee, S. (2013). Brain Tumor Segmentation using Genetic Algorithm and Artificial Neural Network

Fuzzy Inference System ANFIS. *Advances in Intelligent Systems and Computing*, Springer, Berlin, Heidelberg, 177, 329-339.

Wu, M., Lin, C. & Chang, C. (2007). Brain tumor detection using color-based k-means clustering segmentation. *Conference on Intelligent Information Hiding and Multimedia Signal Processing*, 245-250.

Zhang, J., Ma, K., Er, M. & Chong, V. (2004). Tumor segmentation from magnetic resonance imaging by learning via one-class support vector machine. *Workshop on Advanced Image Technology*, 207-211.