

**DS ve FCM TABANLI YENİ BİR GÖRÜNTÜ KÜMELEME ALGORİTMASI**  
**A NOVEL IMAGE CLUSTERING ALGORITHM BASED ON DS and FCM**Metin TOZ<sup>1</sup>, Güliz TOZ<sup>2</sup><sup>1</sup>Teknoloji Fakültesi Bilgisayar Mühendisliği Bölümü  
Düzce Üniversitesi  
{metintoz}@düzce.edu.tr<sup>1</sup>FBE Elektrik-Elektronik ve Bilgisayar Mühendisliği ABD  
Düzce Üniversitesi  
{glz.toz}@gmail.com**Özetçe**

Görüntünün benzer özelliklere sahip piksellerden oluşan kümeler ayrılması işlemi olan görüntü kümeleme, medikal görüntüler üzerinde gerçekleştirilecek görüntü işleme süreçlerin önemli aşamalarındandır. Bu çalışmada yeni bir eniyileme algoritması olan Diferansiyel Arama algoritması (DS) ile Bulanık Kümeleme Algoritması (FCM) birleştirilerek yeni bir görüntü kümeleme algoritması geliştirilmiştir. Birleştirme işleminde FCM algoritmasının amaç fonksiyonu DS algoritması kullanılarak minimize edilmiştir. Test amacıyla 3 farklı beyin MRI görüntüsü geliştirilen yeni algoritma ve klasik FCM algoritması kullanılarak kümelendirilmiştir. Her iki algoritma amaç fonksiyon değerleri açısından karşılaştırılmıştır. Elde edilen sonuçlara göre yeni geliştirilen algoritma görüntü kümeleme konusunda klasik FCM algoritmasından çok daha iyi performans göstermiştir.

**Anahtar Kelimeler** — FCM; DS; görüntü kümeleme.**Abstract**

Image clustering, the separation process of the image to the clusters which have pixels with similar properties is one of the most important sections of the image processing procedures. In this study we developed a novel image clustering algorithm by combining Differential Search algorithm (DS) which is a new optimization algorithm and Fuzzy Clustering Algorithm (FCM). Combining procedure was realized by minimizing the objective function of FCM by DS. As for testing purposes 3 brain MRI images were clustered by the new algorithm and the classical FCM. Both of the algorithms were compared in terms of objective function values. According to the results, the new algorithm out performs the classical FCM algorithm in terms of image clustering.

**Keywords** — FCM; DS; image clustering.**1. Giriş**

Görüntü kümeleme, medikal görüntü işleme süreçlerinde görüntü üzerinde ilgilenilen bölgenin ortaya çıkarılması amacıyla sıklıkla kullanılmaktadır [1]. Kümeleme işleminde görüntüde yer alan piksellerin belirli özelliklerine göre kümeler ayrılması ve bu şekilde benzer özelliklere sahip görüntü kısımlarının öne çıkarılması ve ayrıca istenmeyen kısımların ise görüntüden atılması amaçlanır. Literatürde bu konuda yapılmış çalışmalara bakıldığında en çok kullanılan

yöntemlerden birinin bulanık mantık temelli FCM (Fuzzy C-Means) algoritması olduğu görülmektedir. Bu algoritma ilk olarak Dunn [2] tarafından önerilmiş ve Bezdek [3] tarafından geliştirilmiş, günümüze kadar birçok farklı alanda kullanılmıştır [4]. Ancak FCM algoritmasının iki temel dezavantajı bulunmaktadır. Bunlardan birincisi FCM nin çözülen problemin lokal minimum noktalarına kolayca takılabilmesi diğeri ise kümeler için merkez noktalarının başlangıçta nasıl seçildiğidir [5]. Literatüre bakıldığında, FCM algoritmasının bu dezavantajlarını gidermek için genellikle FCM ile diğeri bir algoritmanın birleştirildiği görülmektedir. Örneğin, Yong-Feng ve Shu-Ling [5] çalışmalarında klasik FCM algoritması ile Parçacık Sürü Optimizasyon (PSO) algoritmasını birleştirip yeni bir kümeleme algoritması önermişlerdir. Yazarlar yeni algoritmanın kızılotesi kamera görüntülerinin kümelendirilmesi için de kullanılabilirliğini göstermişlerdir. Gao ve arkadaşları [6], çalışmalarında Genetik Algoritma (GA) ve FCM'yi birleştirerek görüntü tanıma amacıyla kullanmışlardır. Karnan ve Gopal [7], çalışmalarında beyin MRI resimlerinde kümeleme yapmak amacıyla Karınca Kolonisi Optimizasyon algoritması (ACO) ve FCM'yi birlikte kullanarak hibrid bir kümeleme algoritması geliştirmişlerdir. Verilen örnek çalışmalara bakıldığında FCM nin çoğunlukla sezgisel veya evrimsel optimizasyon algoritmaları ile birleştirildiği görülmektedir. Bu çalışmada da en son geliştirilen sezgisel optimizasyon algoritmalarından biri olan Diferansiyel Arama (DS) algoritmasının FCM ile birleştirilmesi ile yeni bir görüntü kümeleme algoritması geliştirilmesi amaçlanmıştır. DS algoritması Civicioğlu [8] tarafından 2013 yılında geliştirilmiştir. Civicioğlu [8] çalışmasında DS, GSA ve PSO dahil bir çok farklı sezgisel optimizasyon algoritmalarını farklı problem setlerini kullanarak test etmiş ve DS nin diğeri algoritmalarından daha iyi performans gösterdiğini ortaya koymuştur. DS algoritması literatürde birçok farklı problem çözümünde de kullanılmıştır [9-10]. Bu çalışmada klasik FCM algoritması DS algoritması ile birleştirilerek yeni hibrid bir görüntü kümeleme algoritması geliştirilmiş ve bu algoritmaya DSFCM görüntü kümeleme algoritması ismi verilmiştir. Geliştirilen algoritmanın temeli FCM'nin amaç fonksiyonunun DS ile minimize edilmesi esasına dayanmaktadır. Geliştirilen algoritmanın test edilmesi amacıyla [11]'de yer alan veri tabanından seçilen 3 farklı beyin MRI görüntüsü üzerinde hem klasik FCM algoritması ile hem de DSFCM algoritması ile görüntü kümeleme işlemleri gerçekleştirilmiştir. Elde edilen sonuçlar amaç fonksiyon değerleri açısından karşılaştırılmıştır. Buna göre yeni geliştirilen DSFCM algoritmasının klasik FCM

**Tıbbi Görüntüleme 3**

2. Gün / 16 Ekim 2015, Cuma

algoritmasından çok daha iyi sonuçlar ürettiği gösterilmiştir. Çalışmanın devamı şu şekilde organize edilmiştir. İkinci bölümde klasik FCM ve DS algoritmaları hakkında temel bilgilere ve yeni geliştirilen DSFCM algoritmasına yer verilmiştir. Deneysel çalışmalar üçüncü bölümde ve tüm çalışmanın özeti de dördüncü bölümde ele alınmıştır.

**2. Çalışmada Kullanılan Algoritmalar****2.1. FCM Algoritması**

FCM algoritması 1981 yılında Bezdek [3] tarafından geliştirilmiş bir veri kümeleme algoritmasıdır. Kümeleme işlemi, görüntü işleme açısından görüntünün benzer özelliklere sahip piksellerinin gruplandırılması olarak tanımlanabilir. Örneğin gri seviye bir görüntüde piksellerin gri-seviye değerlerine göre kümelendirilmesi istenildiğinde her bir kümede yer alacak piksellerin gri seviye değerlerinin birbirlerine mümkün olduğunca yakın olması amaçlanır. FCM algoritması bu işlemi gerçekleştirirken bulanık mantık yaklaşımı ile hareket eder. Buna göre bir pikselin sadece bir kümeye ait olması yerine aynı pikselin tüm kümelere farklı bir değer ile temsil edilmesi sağlanır. Bu değere  $u_{i,j}$  pikselin kümedeki üyelik değeri adı verilir ve bu değer  $[0-1]$  aralığındadır. Buna göre kümeleme işlemi bir  $V$ , veri setinde yer alan  $n$  tane elemanın  $c$  tane kümeye ayrılması olarak tanımlanabilir. Buna göre bir veri seti aşağıdaki gibi tanımlanabilir [12].

$$V = (v_1, v_2, v_3, \dots, v_n) \quad (1)$$

Veri setinde yer alan her bir eleman her bir küme üzerinde bir üyelik değerine sahiptir. Tüm üyelik değerlerinin bir arada tutulduğu matrise de üyelik matrisi denir. Bu durum aşağıdaki gibi gösterilebilir [12].

$$U = u_{i,j} \in [0,1]_{c \times n} \quad (2)$$

Denklemden  $U$  tüm elemanların üyelik değerlerinin tutulduğu üyelik matrisi,  $u_{i,j}$  ise veri setindeki  $j$ . elemanın  $i$ . kümede yer alan üyelik değeridir. Üyelik matrisi Denklem 3'te verilen kriterleri sağlamalıdır [12]. FCM algoritması kümeleme işlemi yaparken Denklem 4'te verilen amaç fonksiyonu minimize eder.

$$\sum_{i=1}^c u_{i,j} = 1, \quad 0 \leq \sum_{j=1}^n u_{i,j} < n, \quad 0 \leq u_{i,j} \leq 1 \quad (3)$$

$$O = \sum_{i=1}^c \sum_{j=1}^n (u_{i,j})^m (d_{i,j})^2 \quad (4)$$

Denklemden  $O$  amaç fonksiyon,  $m$  bulanık mantık sabiti ve  $d_{i,j}$  ise  $j$ 'nci elemanın  $i$ 'nci küme merkezine olan uzaklığıdır. Bu uzaklık aşağıdaki gibi hesaplanmaktadır [12].

$$d_{i,j} = \|h_i - v_j\| \quad (5)$$

Denklemden  $h_i$ ,  $i$ 'nci kümenin merkezidir ve  $v_j$ 'nci elemanın  $i$ 'nci küme merkezine olan uzaklığı iki elemanın farkının mutlak değeri alınarak bulunmaktadır. FCM algoritması denklemler 1-5 te yer alan işlemleri belirli bir durdurma kriteri sağlanana kadar tekrar eder. Durdurma kriteri olarak üyelik matrisindeki değişimin belirli bir eşik değerinin altına düşmesi seçilebileceği gibi belirli bir döngü sayısı da bu

amaç için kullanılabilir. Bu çalışmada durdurma kriteri olarak 60 döngü sayısı kullanılmıştır.

**2.2. DS Algoritması**

Diferansiyel arama algoritması Civicioğlu [8] tarafından 2012 yılında geliştirilmiş bir optimizasyon algoritmasıdır. Bu algoritmanın temeli canlı sürülerinin yaşamlarını sürdürebilmek için yiyecek kaynaklarına doğru yaptıkları göç hareketlerine dayanır. Göç sırasında canlıların gösterdikleri hareket şekli Brownian türü rastgele hareket modeli olarak isimlendirilmektedir ve DS algoritması bu hareket şeklinin simülasyonu esasına dayanır [8]. Buna göre sürü göç süresince yeni konaklama alanları arar, bu alanların konaklamaya uygunluk derecesi çözülecek problem için önerilen amaç fonksiyon değerleri ile belirlenir. Eğer yeni bir alan konaklama için uygunsuz sürü yeni konumu olarak bu alanı belirler ve göç süreci bu alandan devam eder. DS algoritmasında çözülecek problem için kullanılacak aday çözümlerin yer aldığı popülasyon bir yapay süper organizma olarak tanımlanmıştır. Bu popülasyon problemin global çözümüne doğru hareket eder ve popülasyonda yer alan her bir aday çözüm ise bir yapay organizma olarak tanımlanır [8]. DS algoritmasının adım adım işleyişi şu şekilde ifade edilebilir [8]. Popülasyonda yer alan bir yapay organizma aşağıdaki gibi tanımlanabilir [8].

$$x_{i,j} = rand.(Ust_j - Alt_j) + Alt_j \quad (6)$$

Denklemden  $i=1,2,3,\dots,N$  ve  $j=1,2,3,\dots,D$  sırasıyla yapay organizma indisi ve boyutudur. Buna göre süper organizmada yer alan yapay organizma sayısı  $N$ , her bir yapay organizmanın boyutu ise  $D$ 'dir. Son olarak,  $Ust_j$  ve  $Alt_j$  ise sırasıyla aynı organizmanın  $j$ 'nci boyutunun üst ve alt limitleridir. Buna göre bir yapay organizma,  $X_i$  ve bir süper organizma  $Y$ , aşağıdaki gibi tanımlanabilir [8].

$$X_i = [x_{i,j}] \quad ; \quad Y = [X_i] \quad (7)$$

Geçici bir konaklama alanı ise aşağıdaki denklem ile bulunmaktadır [8].

$$K_g = Y + s \times (Y_d - Y) \quad (8)$$

Denklemden  $s$   $[0,1]$  aralığında rastgele üretilen bir sayıdır.  $Y_d$  ise  $Y$ 'nin her bir üyesinin (yapay organizma) elemanlarının rastgele yer değiştirilmesi ile elde edilen bir matristir [8]. DS algoritmasında ayrıca  $p_1 = rand \times 0.3$  ve  $p_2 = rand \times 0.3$  olarak tanımlanan iki parametre kullanarak  $Y$ 'nin rastgele seçilen bazı elemanlarının  $K_g$ 'nin yapısına değişmeden katılması sağlanmaktadır. Bu rastgele seçim sürecinin detayları için [8]'e bakılabilir. Buna göre Denklem 8 aşağıdaki gibi ifade edilebilir.

$$K_g = Y + (s \times M) \times (Y_d - Y) \quad (9)$$

Denklemden  $M$  matrisi  $Y$  ile aynı boyutta rastgele elde edilmiş ve 1 ve 0 lardan oluşan bir matristir. Bu matrisin 0 içeren elemanlarına karşılık gelen  $K_g$  elemanlarının yerine  $Y$ 'nin elemanları değişmeden katılmaktadır. Son olarak elde edilen  $K_g$  matrisi için amaç fonksiyonu değerleri hesaplanmakta ve elde edilen sonuçlara göre  $Y$  matrisi güncellenerek yeni popülasyon oluşturulmaktadır. Güncelleme

## Tıbbi Görüntüleme 3

2. Gün / 16 Ekim 2015, Cuma

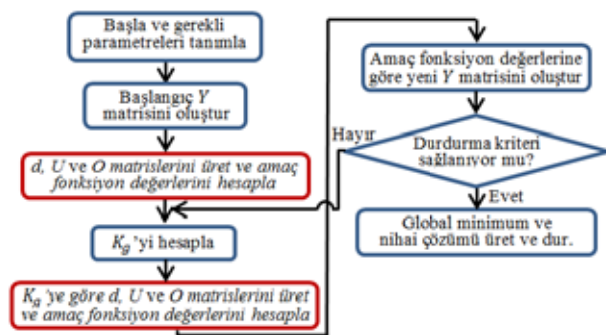
işleminde  $K_g$ 'nin elemanları ile  $Y$ 'nin elemanları amaç fonksiyonu değerleri açısından karşılaştırılmakta ve daha iyi amaç fonksiyonu değeri üreten  $K_g$  elemanları ilgili  $Y$  elemanlarının yerini almaktadır. Algoritmanın sözde kodu için [8]'e bakılabilir.

### 2.3. FCM ve DS Algoritmalarının Birleştirilmesi

FCM algoritması oldukça hızlı ve verimli bir veri kümeleme algoritması olması ile birlikte bu algoritmanın iki önemli dezavantajı vardır. Bunların ilki FCM'nin başlangıç aşamasında rastgele seçilen küme merkezlerinin algoritmanın performansını etkilemesi diğeri ise lokal minimuma takılma problemi [5]. Literatüre bakıldığında FCM'nin bu dezavantajlarının giderilmesi için çoğunlukla diğer eniyileme algoritmaları ile birleştirildikleri görülmektedir. Bu çalışmada da FCM'nin bu dezavantajlarını ortadan kaldırmak amacıyla FCM ile DS algoritması birleştirilmiştir. Bu amaçla ilk olarak DS algoritması için gerekli olan popülasyon tanımlaması Denklem 10'daki gibi yapılmıştır.

$$Y = \begin{bmatrix} x_{1,1} & \dots & x_{1,D} \\ \vdots & & \vdots \\ x_{N,1} & \dots & x_{N,D} \end{bmatrix} \quad (10)$$

Denkleme göre başlangıç nüfusu  $N \times D$  lik bir matris şeklinde tanımlanmıştır. Bu matrisin her bir satırında FCM için belirlenecek küme sayısına eleman bulunmaktadır. Buna göre her bir satır kümeleme işlemi için gerekli aday küme merkezlerinden oluşmaktadır. Birleştirme aşamasının diğer aşaması FCM'nin Denklem 4'te verilen amaç fonksiyonunun DS algoritması kullanılarak minimize edilmesidir. Bu şekilde yapılacak birleştirme sonucunda FCM algoritması ile veri setindeki üyelerin küme merkezlerine olan uzaklığı, üyelik değerleri ve amaç fonksiyonları hesaplanacak; DS algoritması ile de hesaplanacak amaç fonksiyon değerlerine göre küme merkezlerinin güncellenmesi sağlanacaktır. İki algoritmanın birleştirilmesi sonucu oluşan algoritmaya DSFCM veri kümeleme algoritması adı verilmiştir. Bu algoritmanın akış şeması Şekil 1'de sunulmuştur. Şekilde kırmızı ile gösterilen bloklar FCM algoritması tarafından gerçekleştirilen aşamaları mavi bloklar ise DS algoritması tarafından gerçekleştirilen aşamaları göstermektedir.




Şekil 1: DSFCM algoritmasının akış şeması.

### 3. Deneysel Çalışmalar

Bu çalışmada önerilen DSFCM algoritmasının görüntü kümeleme konusundaki performansını test edebilmek için [11]

de tanımlan veri tabanında yer alan beyin MRI görüntüleri kullanılmıştır. Bu görüntülerin seçilmiş olmasının nedeni ilgili görüntülerde yer alan kanserli bölgelerin önceden konunun uzmanlarınca işaretlenmiş olmasıdır. Karşılaştırma amacıyla 3 ayrı görüntü seçilmiştir. Bu görüntüler ve aynı görüntülere ait kanserli bölgelerin belirttiği görüntüler Şekil 2'de görülmektedir.




Şekil 2: Beyin MRI görüntüleri (a) Gri-seviye görüntü (b) Tümörün işaretlenmiş olduğu görüntü.

Beyin MRI görüntülerinde yer alan tümörlü kısımların görüntü üzerinden seçilebilmesi için ilk olarak görüntünün tamamında yer alan piksellerin benzer özelliklerine göre kümelere ayrılması gerekmektedir. Bu amaçla yapılan deneysel çalışmalarda her üç görüntü hem klasik FCM algoritması hem de önerilen DSFCM algoritması kullanılarak 100'er defa birbirinden bağımsız olarak kümelendirilmiştir. Kümelendirme işlemlerinde her iki algoritma için kullanılan ortak parametreler; Popülasyon büyüklüğü: 40, döngü sayısı: 60, küme sayısı: 3 ve  $m : 2$  olarak alınmıştır. Tüm deneysel çalışmalar aynı şartlar altında Intel i-3 3.1 GHz işlemci ve 4 GB ram özelliklerine sahip bir bilgisayar kullanılarak gerçekleştirilmiştir. Elde edilen sonuçlara göre her iki algoritmanın 100 çalışma sonucunda elde ettiği en iyi amaç fonksiyon değerlerine göre çizdirilen kümelendirilmiş resimler Şekil 3'te sunulmuştur. Şekil 3'e göre her iki algoritma da resimleri tümörlü bölgeleri gösterecek şekilde başarı ile kümelemiştir. Resimlerden iki algoritma arasındaki farklılıkları görmek ilk bakışta pek mümkün değildir. Örnek olarak Şekil 3, 2a ve 2b arasındaki bir fark Şekil 4'te gösterilmiştir. Şekle göre DSFCM ile üretilen görüntüde tümörlü bölgenin FCM ile elde edilen görüntüye göre daha iyi bir şekilde ortaya çıktığı görülmektedir. Ayrıca, iki algoritmanın başarısını karşılaştırmak için yapılan 100 çalıştırma sonucunda elde edilen amaç fonksiyon değerleri de her üç resim için grafiksel olarak Şekil 5'de gösterilmiştir. Grafiklere göre DSFCM'nin 100 çalıştırmanın Resim 1 için 97'sinde, Resim 2 için 99'unda ve Resim 3 için 70'inde daha iyi amaç fonksiyon değerleri elde ettiği görülmektedir. Bu sonuçlara göre önerilen DSFCM algoritmasının klasik FCM algoritmasından görüntü kümeleme konusunda çok daha iyi performans gösterdiği açık bir şekilde görülebilmektedir. Ayrıca; elde edilen amaç fonksiyon değerleri arasındaki farklılıklara (Örn. Resim 2 için DSFCM, FCM den ortalama 36,51 daha düşük değerlere ulaşmıştır.) bakılarak; FCM nin DS ile birleştirilmesinin FCM'nin lokal minimuma takılma ve başlangıç değerlerinden etkilenme gibi problemlerini giderdiği de söylenebilir.




## Tıbbi Görüntüleme 3


2. Gün / 16 Ekim 2015, Cuma




Şekil 3: Deneysel çalışmalar sonucunda FCM ve DSFCM algoritmaları ile kümelmiş resimler (a) FCM (b) DSFCM




Şekil 4: (a) Orijinal, (b) FCM ve (c) DSFCM fark örneği



(a)



(b)



(c)

Şekil 5: FCM ve DSFCM algoritmaları ile elde edilen amaç fonksiyon değerleri a) Resim 1 b) Resim 2 ve c) Resim 3.

## 4. Sonuçlar

Görüntü kümeleme amacıyla literatürde oldukça sık kullanılan klasik FCM algoritması ile yeni bir eniyileme algoritması olan DS algoritması birleştirilerek yeni bir görüntü kümeleme algoritması, DSFCM, önerilmiştir. Birleştirme işlemi FCM algoritmasının amaç fonksiyonu DS algoritması kullanılarak minimize edilmiştir. Önerilen algoritmanın performansı, 3 farklı beyin MRI görüntüsünün her biri için 100'er defa çalıştırılması suretiyle test edilmiştir. Elde edilen sonuçlara göre DSFCM algoritması klasik FCM algoritmasından çok daha iyi amaç fonksiyon değerleri elde etmiştir. Buna göre DS ile birleştirme işleminin FCM'nin lokal minimuma takılma ve başlangıç değerlerinden etkilenme gibi dezavantajlarını giderdiği sonucuna ulaşılmıştır.

## 5. Kaynakça

- [1] Alan, A. ve Becerikli, Y., "Bulanık Kural Tabanı Sistemi ile Tümör Tespiti", *6<sup>th</sup> International Advanced Technologies Symposium (IATS'11)*, 2011, 25-28.
- [2] Dunn, J. C., "A Fuzzy Relative of the ISODATA Process and its Use in Detecting Compact Well Separated Clusters", *Journal of Cybernetics*, vol. 3, pp. 32-57, 1974.
- [3] Bezdek, J. C., *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [4] Yang Y., "Image Segmentation by Fuzzy C-Means Clustering Algorithm with a Novel Penalty Term", *Computing and Informatics*, vol. 26, 17-31, 2007.
- [5] Yong-Feng, X. ve Shu-Ling, Z., "Fuzzy Particle Swarm Clustering of Infrared Images", *Second International Conference on Information and Computing Science, ICIC '09*, 2009, 122-124.
- [6] Gao, Y., Wang, S. ve Liu S., "Automatic Clustering Based on GA-FCM for Pattern Recognition," *Second International Symposium on Computational Intelligence and Design*, 2009, 146-149.
- [7] Karnan, M. ve Gopal N.N., "Hybrid Markov Random Field with Parallel Ant Colony Optimization and Fuzzy C Means for MRI Brain Image segmentation", *IEEE International Conference on Computational Intelligence and Computing Research*, 2010, 1-4.
- [8] Civicioglu, P., "Transforming geocentric cartesian coordinates to geodetic coordinates by using differential search algorithm", *Computers & Geosciences*, vol. 46, 229-247, 2012.
- [9] Gan, L. Ve Duan, H., "Biological Image Processing via Chaotic Differential Search and lateral Inhibition", *Optik*, vol. 125, 2070-2075, 2014.
- [10] Amrane, Y., Boudour, M. Ve Belazzoug, M., "A new Optimal reactive power planning based on Differential Search Algorithm", *Electrical Power and Energy Systems*, vol. 64, 551-561, 2015.
- [11] Menze, B., Reyes, M., Van Leemput, K. "The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)" *IEEE Transactions on Medical Imaging*, vol. PP, doi: 10.1109/TMI.2014.2377694, 2014.
- [12] Xia, K., Wu, Y., Ren, X. ve Jin, Y. "Research in Clustering Algorithm for Diseases Analysis." *Journal of Networks*. Vol. 8, 1632-1639, 2013.