

## UYDU GÖRÜNTÜLERİNİN YAPAY ARI KOLONİSİ (ABC) ALGORİTMASI İLE BÖLÜTLENMESİ

T. Kurban<sup>1</sup>, E. Beşdok<sup>2</sup>, A.E. Karkınlı<sup>3</sup>

Erciyes Üniversitesi, Harita Mühendisliği Bölümü, 38039, Melikgazi, Kayseri.  
<sup>1</sup>tubac@erciyes.edu.tr, <sup>2</sup>ebesdok@erciyes.edu.tr, <sup>3</sup>aekarkinli@erciyes.edu.tr

### ÖZET

Yüksek çözünürlüklü uydu görüntüleri yeryüzünde birçok alan hakkında bilgi çıkarımı açısından çok önemlidir. Uydu görüntüleri tarım, jeoloji, ormancılık, bölgesel planlama ve eğitim gibi birçok alandaki çeşitli amaçlı uygulamalarda kullanılmaktadır. Uydu görüntülerinde benzer özellik gösteren alanların belirlenmesi birçok uygulama açısından kolaylık sağlamaktadır. Çok büyük olan bu görüntülerin incelenmesini kolaylaştırmak için bu işlem otomatik hale getirilmektedir. Bu çalışmada uydu görüntüleri K-ortalama, bulanık C-ortalama ve yapay arı kolonisi optimizasyon algoritması yardımıyla bölütlenmiş ve algoritmaların performansları karşılaştırılmıştır.

**Anahtar Sözcükler:** ABC Algoritması, K-Ortalama, Bulanık C-Ortalama, İmge Bölütleme

## SEGMENTATION OF THE AERIAL IMAGES WITH ARTIFICIAL BEE COLONY (ABC) ALGORITHM

### ABSTRACT

High resolution aerial images are very important to obtain information about earth surface. Aerial images can be used in many areas such as agriculture, geology, forestry, regional planning and education. Determining the visually similar areas that is called segmentation is provide convenience for various applications. To facilitate the analysis of these big images, segmentation process is performed automatically. In this study, aerial images are segmented using K-means, fuzzy C-means and artificial bee colony optimization algorithm. Segmentation performances of the algorithms are discussed.

**Keywords:** ABC algorithm, K-means, fuzzy C-means, image segmentation

## 1. GİRİŞ

Günümüzde çok önemli bir bilgi kaynağı olan uydu görüntülerinin kullanımı her geçen gün yaygınlaşmaktadır. Genel olarak uydu görüntüleri bilgi örtüsü, zemin sınıfları, inşaa alanları, yollar ve nehirler, dereler, göller gibi su kütlelerinin dağılımının tespit edilmesi ile çevresel değerlendirme ve görüntüleme, tarım, ölçme bilgisi, kartoğrafya ve askeri alanlarda kullanılmaktadır (Guarnieri ve Vettore, 2002, Awad ve ark., 2007). Uydu görüntüleri tarım alanında, tarım ürünlerinin ekiminin yer, zaman ve miktarının planlanması için verimli bir şekilde kullanılmaktadır. Ayrıca ürünlerin gelişimleri ve tarım politikalarının uygulanma düzeyi gibi bilgiler de yine uydu görüntülerinin analiz edilmesi ve yorumlanması ile elde edilebilir (Yalnız ve Aksoy, 2009). Uydu görüntülerinden bina tespiti diğer bir uygulama alanıdır. Görüntülerden elde edilen bilgi şehir planlanması, altyapı gelişimi ve doğal afet planlanması gibi birçok uygulama açısından önem taşımaktadır (Sümer ve Yılmaz, 2008).

Görüntü bölütleme, bir görüntüyü her biri içerisinde farklı özelliklerin tutulduğu anlamlı bölgelere ayırma işlemidir. Bölütlemenin amacı görüntüyü daha anlamlı ve analiz edilmesi kolay bir şekilde göstermektir. Görüntü bölütleme bir görüntüdeki nesnelere ve sınırların yerini öğrenmek için kullanılır. Bir bölgedeki her bir piksel renk, yoğunluk veya doku gibi karakteristik özellikleri veya hesaplanmış özelliklerine göre birbirine benzerlik gösterirken, farklı bölgelerdeki piksellerin özellikleri ise farklılık göstermektedir. Görüntünün analiz edilmesi aşamasında görüntüden elde edilen böyle bir bilgi tıbbi görüntüleme, uydu resimlerinden nesnelere yerlerinin tespiti, yüz tanıma, parmak izi tanıma ve otomatik trafik kontrol sistemleri gibi birçok uygulamada kolaylık sağlamaktadır (Hedberg, 2004, McCoy, 1997, Omran ve ark., 2006).

Görüntü bölütleme problemi için geliştirilen birçok teknik vardır. Ancak tüm bu tekniklerin başarısı görüntünün özelliklerine göre farklılık göstermektedir. Çok fazla detay içeren görüntülerin bölütlenmesinde hiçbir algoritma tam olarak başarı sağlayamamaktadır (Karaboğa ve Baştürk, 2005, Francis ve ark., 1998, Zhang ve Desai, 2001).

Görüntü bölütleme işleminde sınıflandırma metotları, kümeleme metotları, histogram temelli metotlar, kenar tespit metotları ve bölge büyütme metotları gibi birçok yöntem geliştirilmiştir.

Bu çalışmada görüntü bölütleme işlemi bir optimizasyon problemi olarak ele alınmış ve yüksek çözünürlüklü bir uydu görüntüsünün yapay arı kolonisi optimizasyon algoritması ile bölütlenmesi işlemi gerçekleştirilmiştir. Algoritmanın performansını değerlendirebilmek için aynı uydu görüntüsü klasik bir yöntem olan K-ortalama algoritması ve bulanık C-ortalama algoritması ile bölütlenmiş ve elde edilen sonuçlar değerlendirilmiştir.

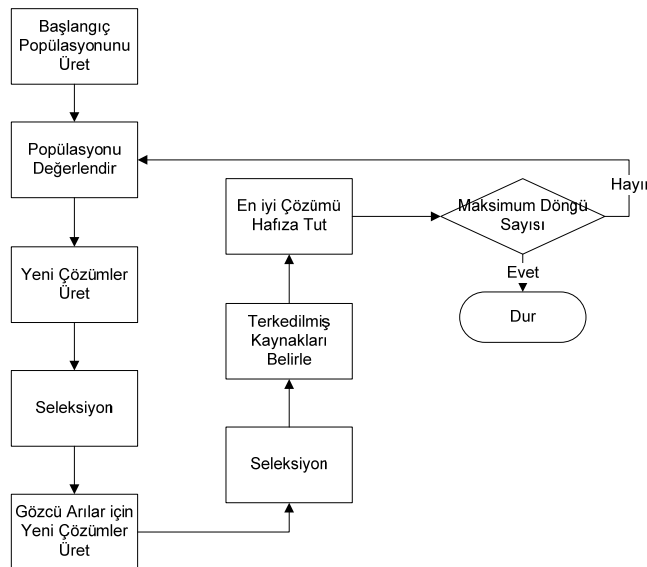
## 2. GÖRÜNTÜ BÖLÜTLEME

Görüntü bölütleme işleminde tercih edilen klasik bir algoritma olan K-ortalama algoritmasında, başlangıçta  $K$  adet sınıf merkezi belirlenir. Bu merkezler rastgele seçilebileceği gibi veri kümesinden örnekler seçilerek de elde edilebilir. Sonrasında resimdeki tüm pikseller en yakın sınıf merkezine atanır. Her bir sınıfın yeni merkezi, o sınıftaki piksel değerlerinin ortalaması alınarak elde edilir. Bu işlemler belli sayıda veya sınıf merkezlerinin değişiminin durmasına kadar devam edilir.

Bulanık C-Ortalama (Fuzzy C-means-FCM), her bir verinin bir sınıfa belli bir üyelik fonksiyonu derecesinde ait olduğu bir bölütleme yöntemidir. Bu teknik ilk olarak Jim Bezdek tarafından daha önceki bölütleme yöntemlerinin gelişmiş bir versiyonu olarak önerilmiştir (Bezdec, 1981, Bezdec ve ark., 1993). Çok boyutlu bir uzayda farklı sayıda sınıfa dağılan verilerin nasıl gruplanacağını gösteren bir yöntemdir. Sınıf merkezleri için rastgele değerler seçilir. FCM her bir veriyi bir üyelik fonksiyonu ile her bir sınıfa sırayla atar. İteratif olarak sınıf merkezlerinin ve üyelik fonksiyon derecelerinin güncellenmesiyle sınıf merkezleri doğru yerlerine oturmaya başlar. Bu iterasyonlar, her bir verinin ait olduğu sınıf merkezine uzaklığının ilgili verinin üyelik fonksiyonunun ağırlıklandırılması ile hesaplanan bir amaç fonksiyonunun minimize edilmesine bağlıdır.

## 3. YAPAY ARI KOLONİSİ ALGORİTMASI

Yapay Arı Kolonisi Algoritması (ABC) Karaboğa tarafından 2005 yılında önerilen sezgisel bir optimizasyon algoritmasıdır. ABC bal arılarının yiyecek arama davranışlarından esinlenilerek oluşturulan bir algoritmadır. ABC modelinde koloni işçi arıları, gözcü arılar ve kaşif arılar olmak üzere üç farklı arı grubundan oluşmaktadır. Her bir yiyecek kaynağı için bir tane yapay işçi arı olduğu kabul edilir. Bal arılarının yiyecek arama davranışları şu şekilde özetlenebilir: işçi arılar kendi yiyecek kaynaklarına gider, o yiyecek kaynağı için nektar miktarını belirledikten sonra yeni komşu yiyecek kaynakları araştırır, kovana döner ve yiyecek kaynağı hakkında bilgi veren dansını yapar, gözcü arılar işçi arıların dansına göre bir yiyecek kaynağı seçer. Seçilecek Yiyecek kaynağının olasılığı yiyecek nektarının kalitesi ve kalan yiyecek miktarı ile ilişkilidir. Terk edilmiş kaynaklar belirlenir ve kaşif arılar tarafından terk edilenler yerine yeni kaynaklar üretilir. En iyi yiyecek kaynağı belirlenir ve pozisyonu hafızada tutulur. Durdurma kriteri sağlanana kadar bu işlemler devam eder (Karaboga, 2005, Basturk ve Karaboga, 2006, Basturk ve Karaboga, 2007). ABC algoritmasının temel akış diyagramı Şekil 1'de verilmiştir.



Şekil 1. ABC Algoritmasının Temel Akış Diyagramı

ABC algoritmasında bir yiyecek kaynağı optimizasyon probleminde bir olası çözümü ve nektar miktarı ise o yiyecek kaynağının kalite değerini temsil etmektedir. İşçi arı sayısı yiyecek kaynağı sayısını yani olası çözüm sayısını göstermektedir. İlk olarak rasgele dağılımlı popülasyon üretilir. Daha sonra işçi, gözcü ve kaşif arıların araştırma döngüleri sırayla tekrarlanır. Bir işçi arı yiyecek kaynağını değiştirir ve yeni bir kaynak keşfeder. Eğer yeni kaynağın nektar miktarı eskisinden fazla ise eskinin yeni kaynağın pozisyonu öğrenilir. Aksi takdirde eskisi hafızada kalır. Tüm işçi arıların araştırma işlemi bittiğinde pozisyon bilgilerini gözcü arılarla paylaşırlar. Gözcü arılar nektar miktarlarını değerlendirir ve bir kaynağı seçerler (Karaboga, 2005, Basturk ve Karaboga, 2006, Basturk ve Karaboga, 2007).

#### 4. YAPAY ARI KOLONİSİ ALGORİTMASI TABANLI GÖRÜNTÜ BÖLÜTLEME

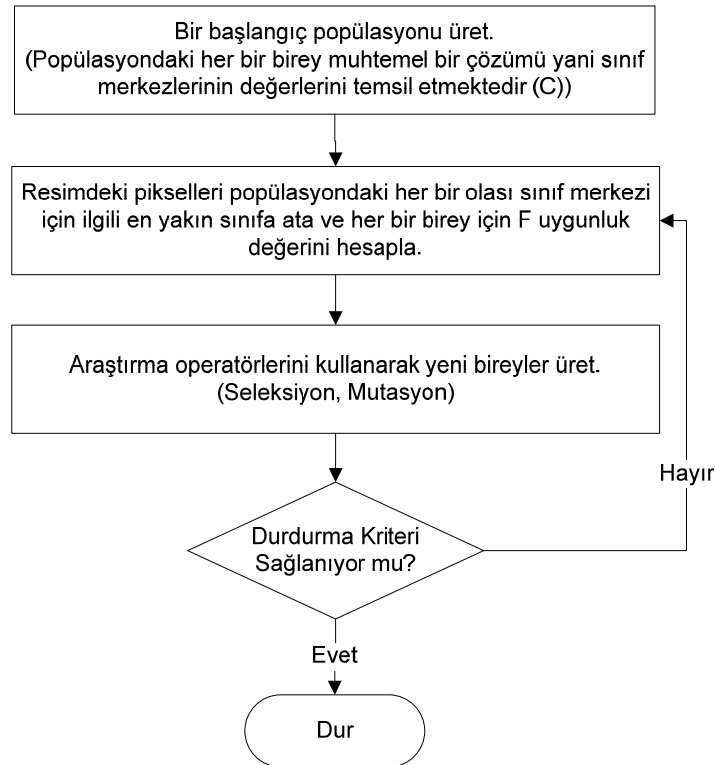
Bölütleme problemi bir optimizasyon problemi olarak da ele alınabilir. Burada amaç sınıf içi benzerliği maksimize etmektir. Sınıf içi benzerliği maksimize etmenin bir yolu sınıftaki elemanların sınıf merkezine olan Öklit uzaklıklarının toplamını minimize etmektir. Öklit uzaklığı Denklem 1’de verilmiştir.

$$E_j = \sqrt{\sum_{i=1}^N (R_i - C_j)^2} \quad (1)$$

Burada,  $R$  sınıftaki elemanları,  $N$  eleman sayısını ve  $C$  ise sınıf merkezlerini belirtmektedir. Bu durumda, optimizasyon algoritması için amaç fonksiyonundaki uygunluk değeri her bir sınıfa ait Öklit uzaklıklarını toplamı olarak Denklem 2’deki gibi tanımlanabilir.

$$F = \sum_{j=1}^K E_j \quad (2)$$

Burada  $K$ , sınıf sayısıdır. Optimizasyon algoritması,  $F$  uygunluk değerini minimize edecek  $C$  değerlerinin bulunmasını sağlamaktadır.



Şekil 2. ABC ile Görüntü Bölütleme İşleminin Temel Adımları

ABC popülasyon tabanlı gelişime dayalı bir optimizasyon algoritmasıdır. Araştırma uzayını paralel olarak tarayarak en uygun çözümün bulunmasını sağlar.

## 5. SİMULASYON SONUÇLARI

Önerilen yöntemin uydu görüntülerinin bölütlenmesi işlemindeki başarısını değerlendirebilmek için 2005 yılı Kayseri bölgesine ait 30m çözünürlüklü Lantsat7 uydu görüntüsü (glovis.usgs.gov.tr) kullanılmıştır.

Deneyle 4, 6 ve 8 sınıf sayıları için k-ortalama, bulanık c-ortalama ve yapay arı kolonisi optimizasyon algoritması ile gerçekleştirilmiştir. 4, 6 ve 8 sınıf için bölütleme sonuçları Tablo 1, Tablo 2 ve Tablo 3’ de verilmiştir.

**Tablo 1.** 4 sınıf için farklı algoritmalara ait MSE hataları ve sınıf merkezleri.

	K-Ort.	Bulanık C-Ort	ABC
Ort MSE	321.1465	321.8696	320.5768
Std. Sap.	0.1820	0.36272	0.0195
1.merkez	35.6137	32.3993	35.0123
2.merkez	99.1181	97.3035	97.8321
3.merkez	149.1154	146.5687	146.9959
4.merkez	215.6340	216.4220	214.1051

**Tablo 2.** 6 sınıf için farklı algoritmalara ait MSE hataları ve sınıf merkezleri.

	K-Ort.	Bulanık C-Ort	ABC
Ort MSE	147.5223	146.5970	145.6082
Std. Sap.	0.8213	0.0202	0.0982
1.merkez	24.1623	22.6637	25.2070
2.merkez	71.4656	72.5202	73.6666
3.merkez	105.7306	106.4857	107.6243
4.merkez	139.4858	139.6953	141.1045
5.merkez	181.5286	181.7795	182.1482
6.merkez	234.7192	237.7923	234.7768

**Tablo 3.** 8 sınıf için farklı algoritmalara ait MSE hataları ve sınıf merkezleri.


	K-Ort.	Bulanık C-Ort	ABC
Ort MSE	82.8236	80.7355	80.3617
Std. Sap.	1.8181	0.2900	0.2234
1.merkez	16.3493	14.6161	17.0475
2.merkez	50.6495	50.0027	51.7015
3.merkez	82.3606	83.3678	83.2820
4.merkez	106.6310	107.9737	107.9867
5.merkez	130.8708	132.5373	133.0786
6.merkez	160.6559	162.3890	162.0159
7.merkez	196.2792	197.6360	196.8822
8.merkez	241.8504	244.7912	241.9112

Orijinal uydu görüntüsü ve 8 sınıf için k-ortalama, bulanık c-ortalama ve yapay arı kolonisi algoritması ile bölütlenmiş görüntüler sırasıyla şekil 3, şekil 4, şekil 5 ve şekil 6’ da görülmektedir.


Elde edilen sonuçlara göre bölütleme işleminde ABC algoritmasının diğer yöntemlere göre daha başarılı olduğu görülmektedir. Sınıf sayısı arttıkça ABC algoritması daha kararlı davranmaktadır. Ancak bu problem için genel olarak algoritmaların elde ettiği sonuçların birbirinden çok farklı olmadığı da görülmektedir.




Şekil 3. Orijinal Görüntü



Şekil 4. K-Ortalama Algoritması ile 8 Sınıfa Bölütlenmiş Görüntü



Şekil 5. Bulanık C-Ortalama Algoritması ile 8 Sınıfa Bölütlenmiş Görüntü



Şekil 6. ABC Algoritması ile 8 Sınıfa Bölütlenmiş Görüntü

## KAYNAKLAR

- Awad, M., Chehdi, M., Nasri, A.**, 2007, Multicomponent Image Segmentation Using a Genetic Algorithm and Artificial Neural Network, *IEEE Geoscience and Remote Sensing Letters*, 4(4):.
- Basturk, B., Karaboga, D.**, 2006, An Artificial Bee Colony (ABC) Algorithm for Numeric function Optimization, *IEEE Swarm Intelligence Symposium*, Indianapolis, Indiana, USA.
- Bezdec, J.C., Hall, L.O., Clarke, L.P.**, 1993, Review of MR image segmentation techniques using pattern recognition., *Med.Phys.*, 20:1335-46.
- Bezdec, J.C.**, 1981, *Pattern Recognition with Fuzzy Objective Function Algorithms*, (Plenum Press, New York).
- Guarnieri, A., Vettore, A.**, 2002, Automated Techniques For Satellite Image Segmentation, *Symposium on Geospatial Theory, Processing and Applications*, Ottawa.
- Yalnız, İ.Z., Aksoy, S.**, 2009, Uydu Görüntülerinde Düzenli Dikim Alanlarının Belirlenmesi, *Sinyal İşleme ve Uygulamaları Sempozyumu*, Kocaeli.
- Sümer, E., Yılmaz, A.T.**, 2008, Yüksek Çözünürlüklü Uydu Görüntülerinden Sınıflandırma ve Bölütleme Tabanlı Bir Yaklaşımla Otomatik Bina Tespiti, 2. *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu*, Kayseri.
- Hedberg, H.**, 2004, A Survey of Various Image Segmentation Techniques, *Undergraduate Course, Digital Images, Compression*, 03/04. Lund, Sweden.
- McCoy, D.F.**, 1997, Artificial Immune Systems and Aerial Image Segmentation, Systems, Man, and Cybernetics, *IEEE International Conference on Computational Cybernetics and Simulation*, 1: 867-872.
- Omran, M.G.H., Salman, A., Engelbrecht, A.P.**, 2006, Dynamic clustering using particle swarm optimization with application in image segmentation, *Pattern Anal Applic*, 8: 332–344 Springer.
- Karaboğa, D., Bastürk, B.**, 2005, Image Segmentation using Differential Evolution Algorithm, *IEEE 13th Signal Processing and Communications Applications Conference*, Kayseri, Turkey.
- Francis, H.Y., Chan, F.K., Lam, H.Z.**, 1998, Adaptive thresholding by variational method, *IEEE Trans. Image Process.*, 7 (3): 468–473.
- Karaboga, D.**, 2005, An Idea Based On Honey Bee Swarm for Numerical Optimization. *Technical Report-TR06*, Erciyes University, Engineering Faculty, Computer Engineering Department.
- Karaboga, D., Basturk, B.**, 2007, A Powerful and Efficient Algorithm for Numerical Function Optimization: Artificial Bee Colony (ABC) Algorithm., *J Global Optim.*, 39, 459-171.
- Zhang, X., Desai, M.D.**, 2001, Segmentation of bright targets using wavelets and adaptive thresholding, *IEEE Trans. Image Process.*, 10 (7): 1020–1030.