

T.C.  
ERCIYES ÜNİVERSİTESİ  
BİLİMSEL ARAŞTIRMA PROJELERİ  
KOORDİNASYON BİRİMİ



**Uzaktan Algılamada Diferansiyel Arama Algoritması (DS) Tabanlı Yeni Bir  
KontROLSÜZ Değişim Belirleme Yaklaşımı**

**Proje No: FBA-2013-4643**

Normal Araştırma Projesi

**SONUÇ RAPORU**

**Proje Yürütücüsü:**

Prof. Dr. Coşkun ÖZKAN  
Mühendislik Fakültesi / Harita Mühendisliği Bölümü

**Araştırmacılar:**

Öğr. Gör. Ümit Haluk ATASEVER  
Mühendislik Fakültesi / Harita Mühendisliği Bölümü

Arş. Gör. Mustafa Hayri KESİKOĞLU  
Mühendislik Fakültesi / Harita Mühendisliği Bölümü

Temmuz 2014

KAYSERİ



## **TEŞEKKÜR**

Bu proje Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi(BAP) tarafından desteklenmiştir. [FBA-2013-4643]

## İÇİNDEKİLER

|                                            |    |
|--------------------------------------------|----|
| ÖZET .....                                 | 5  |
| ABSTRACT .....                             | 6  |
| 1. GİRİŞ .....                             | 7  |
| 2. YÖNTEM .....                            | 8  |
| 2.1 DİFERANSİYEL ARAMA ALGORİTMASI.....    | 10 |
| 3. VERİ SETLERİ VE DENEYSEL SONUÇLAR ..... | 11 |
| SONUÇ .....                                | 14 |
| KAYNAKLAR.....                             | 15 |

## ÖZET

Bu proje kapsamında uydu görüntülerinden deęişim saptama amacıyla, Temel Bileşenler Analizi (TBA) ve Diferansiyel Arama Algoritması kullanılarak geliştirilmiş yeni bir deęişim saptama yaklaşımı sunulmuştur. Model ilk olarak,  $k \times k$  büyüklüğündeki bloklar kullanarak bir öz vektör uzayı hesaplar. Deęişim saptama haritası özellik uzayının Diferansiyel Arama Algoritması (DS) ile deęişim olan ve olmayan bölgeler olarak iki kümeye ayrılır. Kontrolsüz sınıflandırma için sınıf merkezleri ve pikseller arasındaki öklit uzaklıkları toplamının minimizasyonu temelli bir amaç (maliyet) fonksiyonu kullanılmıştır. Geliştirilen yaklaşımının etkinliğini ispatlama için Landsat 5 ve ERS-2 görüntüleri kullanılmıştır. Bu amaçla elde edilen bulgular literatürde sıkça kullanılan yöntemlerle kıyaslanmış ve sunulan yaklaşımın oldukça başarılı sonuçlar elde ettięi gözlemlenmiştir.

**Anahtar Kelimeler:** Kontrolsüz Deęişim Saptama, Diferansiyel Arama Algoritması, TBA

## **ABSTRACT**

In this project, we propose a novel unsupervised change detection approach for multi-temporal satellite images using Principal Component Analysis (PCA) and Differential Search Algorithm (DS). The model firstly computes an eigenvector space using previously created  $k \times k$  blocks. The change detection map is generated by clustering the feature vector as two clusters which are change and unchanged using Differential Search Algorithm. For clustering we have used a cost function based on minimization of Euclidean distance of cluster centers and pixels. To show effectiveness of proposed approach Landsat 5 and ERS-2 data have been used in experimental studies. For this purpose, DS and PCA Based Approach has been compared with many unsupervised change detection methods. Experimental results of optic and SAR images prove that proposed approach is effective for unsupervised change detection.

**Keywords:** Unsupervised Change Detection, Differential Search Algorithm, PCA

## 1. GİRİŞ

Uzaktan algılama disiplininin en önemli çalışma konularından biri belirli bir bölgenin zamansal değişiminin incelenmesidir. Farklı zamanlarda elde edilen uydu görüntüleri kullanılarak bir bölgedeki arazi örtüsü veya arazi kullanımında meydana gelen farklılıklar tespit edilebilmektedir. Orman ve tarım alanlarının izlenmesi, arazi örtüsündeki değişimlerin belirlenmesi, orman yangını sonrası oluşabilecek alansal farkın belirlenmesi gibi önemli problemlerin çözümünde değişim belirleme yaklaşımları etkin olarak kullanılmaktadır (Cihlar et al. 1992, Ghosh et al. 2007, Gopal and Woodcock 1996). Değişim saptama da kontrollü ve kontrolsüz olmak üzere iki farklı yaklaşım vardır. Ancak gerçek dünya problemlerinin çözümünde, kontrollü yaklaşımda kullanılacak eğitim verilerinin temin edilmesindeki zorluklar nedeniyle, eğitim verisine ihtiyaç duymayan kontrolsüz yaklaşımlar kullanılabilir. Bu amaçla kullanılan birçok kontrolsüz değişim belirleme yaklaşımı bulunmaktadır. Değişim saptama işlemi uygulanmadan önce hem optik görüntülerde hem de radar görüntülerindeki radyometrik ve geometrik hatalarının giderilmesi gerekmektedir (Mishra et al. 20012, Ghosh et al. 2007).

Değişim saptama işleminde kullanılan temel yaklaşımlar: değişim vektör analizi (CVA), Görüntü Farkı, Temel Bileşenler Analizi(TBA), Görüntü Oranlamadır (Pacifi et al. 2007, Celik 2009a). Bunların içinde en fazla kullanılan ise Görüntü Farkı (image differencing) temelli yaklaşımlardır.

Son yıllarda, bir çok kontrolsüz değişim saptama yaklaşımı geliştirilmiştir. Bunlardan bazıları EM+ MRF (Bruzzone and Prieto 2000), PCA and K-means (Celik 2009a), Fuzzy Local Information C-Means Clustering Algorithm (FLICM) (Krinidis and Chatzis 2010), Reformulated FLICM (RLICM) (Gong et al. 2012) , Hard C means(HCM) , Hard C-Means Hybridized with Simulated Annealing (SA-HCM), Hard C-Means Hybridized With Genetic Algorithm (GA-HCM), Fuzzy C-Means (FCM) Fuzzy C-Means Hybridized with Genetic Algorithm (GA-FCM) (Ghosh et al. 2011,Hao et al. 2013).

Yukarıda sıralanan yaklaşımlardan HCM, SA-HCM, GA-HCM, GA-FCM genelde optik görüntüler için; FLICM ve RFLICM SAR görüntüler için; PCA-Kmeans FCM ve EM+MRF ise hem optik hem de radar görüntüler için kullanılmaktadır (Ghosh et al. 2011, Gong et al. 2012, Celik 2009b).

Değişim saptama için kullanılan yaklaşımlardan bir kısmı farklı tarihlerdeki görüntülerden, fark görüntüsü veya oran görüntüsü yardımıyla özellik uzayının hesaplanması ve ardından bu özellik uzayının bir kümeleme algoritmasıyla (değişen ve değişmeyen) olarak iki kümeye ayrılmasından ibarettir (Ghosh et al. 2011). İşlemin başarısını arttıran en önemli bileşenlerden biri kümeleme algoritmasının performansıdır. Bu amaçla çok sayıda algoritma kullanılmaktadır (Ghosh et al. 2011, Celik 2009b, Gong et al. 2012 ). Son yıllarda kontrolsüz sınıflandırma veya kümeleme için ise yapay zeka optimizasyon algoritmaları kullanılmaya başlanmıştır. Özellikle klasik optimizasyon yöntemlerinden daha başarılı ve etkin sonuçlar

üretebilmesi nedeniyle bir çok araştırmacı bu algoritmalarından faydalanmaya başlamıştır (Zou et al. 2010, Karaboga and Ozturk 2011). PSO, Genetik Algoritma ve ABC gibi bir çok optimizasyon algoritması olmasına rağmen daha başarılı sonuçlar üretebilme ve hızlı yakınsama özelliğine sahip olan Diferansiyel Arama Algoritması(DS) oldukça dikkat çekmektedir. Civicioglu tarafından geliştirilmiş bu algoritma yapılan birçok multi-modal testte, popüler algoritmalara karşı başarılı olmuştur (Civicioglu 2012). Bundan dolayı sunulan yaklaşımın kümeleme adımı DS algoritması kullanılmıştır.

## 2. YÖNTEM

İlk olarak görüntüler kayıt edilir, radyometrik ve geometrik düzeltmeler yapılmalıdır. Bu işlemler proje kapsamında temin edilen Ecognition yazılı ile yapılmıştır. Bu sayede sensörlerden, atmosferden veya çekim geometrisi gibi analizi olumsuz etkileyecek etmenler giderilmiş olur. Geliştirilen yaklaşımın ikinci adımı fark görüntüsünün hesaplanmasıdır.  $X_{time1}$ ,  $X_{time2}$  sırasıyla aynı coğrafi alana ait farklı tarihlerde alınmış görüntüler ve  $X_{Diff}$  fark görüntüsü olsun. Optik görüntüler için fark görüntüsü  $X_{Diff}$  iki görüntünün yoğunluk değerlerinin farklarının mutlak değerlerinin alınmasıyla hesaplanır. Bu işlem optik görüntüler için Eşitlik-1; SAR görüntüler için Eşitlik-2 ile yapılır:

$$X_{Diff} = |X_{time2} - X_{time1}| \quad (1)$$

$$X_{Diff} = \left| \log \frac{X_{time2}}{X_{time1}} \right| = |\log(X_{time2}) - \log(X_{time1})| \quad (2)$$

Üçüncü adım ise bir önceki adımda hesaplanmış olan  $X_{Diff}$  'in  $k \times k$  bloklara ayrılmasıdır.

Bu oluşan yeni matris  $M_d^p$  olsun.  $M_d^p$  vektör seti PCA ile öz vektör seti oluşturmak için kullanılır.  $M_d^p$  matrisinde,  $p$   $1 \leq p \leq S = \lfloor (R \times C) / (k \times k) \rfloor$  ile tanımlanan bir indeks değeridir. Burada  $S$  vektör seti sayısı,  $R$ ,  $X_{Diff}$  'in satır sayısı,  $C$ ,  $X_{Diff}$  'in sütun sayısıdır. Celik yaptığı çalışmada  $k$  için 3 değerinin daha başarılı sonuçlar ürettiğini göstermiştir. Bu yüzden bu çalışmada  $k=3$  olarak alınmıştır (Celik 2009b). Ardından ortalama vektör seti şu şekilde hesaplanır:

$$\Phi = \frac{1}{S} \sum_{p=1}^S M_d^p \quad (3)$$

Ardından bu ortalama vektörü, her matristen çıkarılır.

$$\Delta_p = M_d^p - \Phi \quad (4)$$

Kovaryans matrisi ise şu şekilde hesaplanır:



$$CM = \frac{1}{S} \sum_{p=1}^S \Delta_p (\Delta_p)^{Tr} \quad (5)$$

Eşitlik-5'te  $Tr$  transpoz alma işlemidir. Daha sonra özvektörler  $e_i$  ve özdeğerler  $\lambda_i$  kovaryans matristen hesaplanırlar. Öz değerler büyükten küçüğe doğru sıralanarak en büyük öz değere karşılık gelen ilk  $n$  adet öz vektör seçilir. Bunun nedeni ise genelde temel bileşenler içinde en çok bilgiyi birkaç bileşenin barındırmasıdır. Bu işlemden sonra, özellik vektör uzayı oluşturulur.

$$v(x, y) = \begin{bmatrix} v1 \\ v2 \\ v3 \\ \vdots \\ v_\sigma \end{bmatrix} \quad (6)$$

Eşitlik-6'da  $1 \leq n \leq k^2$ ,  $v_\sigma = (e_i)^{Tr} (M_d(x, y) - \Phi)$ ,  $1 \leq i \leq n$ ,  $1 \leq x \leq R$  ve  $1 \leq y \leq C$ .

Sunulan yaklaşımın bir sonraki aşaması ise özellik vektör uzayının  $v(x, y)$   $[0,1]$  aralığına normalize edilmesidir. Min-Max normalleştirilmesi de denilen bu yöntem şu şekilde uygulanır:

$$\phi_{new} = \frac{\phi - \phi_{\min}}{\phi_{\max} - \phi_{\min}} \quad (7)$$

Eşitlikte  $\phi_{new}$  dönüştürülmüş değeri,  $\phi$  normalize edilmemiş değeri,  $\phi_{\min}$  özellik uzayındaki minimum değeri,  $\phi_{\max}$  özellik uzayındaki maksimum değeri ifade eder. Min-Max normalleştirilmesinin uygulanmasının nedeni, Diferansiyel Arama Algoritmasının(DS) arama uzayını  $[0,1]$  aralığına çekmektir. Bu işlem DS'nin yakınsama hızını arttırmak için uygulanmıştır.

Sunulan yaklaşımın son aşaması, Min-Max Normalleştirilmesi yapılmış özellik vektör uzayının, Diferansiyel Arama Algoritması kullanılarak iki sınıfa kümelenmesidir. Diferansiyel Arama Algoritmasının kullanılabilmesi için bir amaç fonksiyonu gereklidir. Bu çalışma kapsamında, kümeleme amacıyla kullanılacak minimizasyon foksiyonu aşağıda gösterildiği gibidir:

$$c_j = (x_{ii} \mid \min(\|x_{ii} - cnt_j\|_2)) \quad (8)$$

$$\arg \min \sum \|c_j - cnt_j\|_2 \quad (9)$$

Eşitlikte,  $\| \|_2$  öklit mesafesi,  $x_{ii}$  ii'nci piksel,  $cnt_j$  j.'nci sınıfın merkezi,  $c_j$  j.'nci sınıftaki piksellerdir. Yukarıdaki amaç fonksiyonundan da anlaşılacağı üzere, DS ile sınıf merkezleri kestirilmeye ve her iterasyon da güncellenen sınıf merkezleri ile her bir sınıfa ait pikseller arasında uzaklığın minimum olması amaçlanmaktadır.

Durma kriterlerinin sağlanmasının ardından değişim saptama haritası ortaya çıkar. Ancak DS algoritması sınıf merkezlerini kestirmeye çalışırken rastgele olarak başladığından değişen ve değişmeyen bölgelerin etiket değerleri değişiklik gösterebilmektedir. Yani değişim olmuş bölge her zaman 1 veya 0 etiketini almamaktadır. Bu problemi aşabilmek için basit bir etiket düzeltme ilkesi uygulanabilir. Bu işlem Eşitlik-10'da sunulmuştur.

$$CDM = \begin{cases} CDM, & m_1 = 2 \text{ ve } m_2 = 1 \\ (CDM \times -1) + 3, & m_1 = 1 \text{ ve } m_2 = 2 \end{cases} \quad (10)$$

Eşitlikte  $m_1$  ve  $m_2$  sırasıyla değişen ve değişmeyen alanların etiket değerleridir.

## 2.1 DİFERANSİYEL ARAMA ALGORİTMASI

Diferansiyel arama, reel değerli optimizasyon problemlerinin çözümü için Çivicioğlu tarafından geliştirilmiş popülasyon tabanlı iteratif bir sezgisel optimizasyon algoritmasıdır. Diferansiyel Arama Algoritması bir superorganizmanın göç etmek amacıyla kullandığı brownian benzeri rastgele yürüme hareketini simüle eder. Doğada besin alanlarının verimliliği iklime bağlı olarak değiştiğinden, birçok canlı türü daha verimli alanlara göç ederler. Birçok kuş türü, ateş karıncaları ve arılar gibi bir çok canlı türü dönemsel göç döngüsüne sahiptirler. Göç eden canlılar çok sayıda birey içeren superorganizma meydana getirirler. Ardından superorganizma daha verimli alanlara doğru bulunduğu konumu değiştirmeye başlar. Superormanizmanın bu hareketi brownian benzeri rastgele yürüme ile açıklanabilir.

Yağmacı birçok canlı türü, yeni bir habitata göç etmeden önce o habitatın verimliliğini kontrol ederler. Eğer bu habitatın potansiyeli, onun için superorganizmanın ihtiyaçlarını karşılayabiliyorsa, superorganizma geçici olarak bu yeni bölgeye yerleşir; daha verimli bölgeler bulma amacıyla göçüne devam eder. Diferansiyel Arama Algoritmasında ilgili optimizasyon probleminin çözümlerinden oluşan popülasyonun, göç eden bir superorganizmayı ifade ettiği kabul edilir. Bu superorganizma, habitat içerisindeki iyi lokasyonları konaklama bölgesi olarak seçer. Ardından iyi bir konaklama alanı bulan superorganizma üyeleri (klanlar) bu konaklama alanına geçiş yaparlar. Süperorganizmayı (*i.e.*, *Superorganism<sub>g</sub>*,  $g=1,2,3,...,maxgen$ ) oluşturan yapay organizmalar (klan) (*i.e.*,  $X_i$ ,  $i=\{1,2,3,...,N\}$ ) sayısı söz konusu optimizasyon probleminin boyutuna (*i.e.*,  $x_{ij}$ ,  $j=\{1,2,3,...,Dim\}$ ) eşittir. Diferansiyel Arama Algoritmasında superorganizmanın başlangıç konumu  $x_{i,j}=rand(uplim_j-lowlim_j)+lowlim_j$  formülasyonu ile hesaplanır. Bu eşitlikte  $uplim_j$  ve  $lowlim_j$  değerleri klanların  $j$ . elemanları için tanımlanan habitat sınırlarıdır(Civicioglu 2012).

DS'de konaklama bölgesi arama işlemi basit bir brownian benzeri rastgele yürüme model ile açıklanır (Vito, T.2011). Klandan rastgele olarak seçilen sınırlı sayıdaki bireyler göç sürecinin başarısı için önemli olan parametrelerden yeni konaklama bölgeleri bulmak için  $donor=[X_{Rand-Shuffling(i)}]$  hedeflerine doğru ilerler. *Rand-Shuffling* fonksiyonu  $X_i$  seti içerisindeki elemanlarının sıralaması değiştirmek için kullanılırlar. Yapay organizmaların

konumlarındaki değişimler ölçek faktörü kullanılarak belirlenir. Ölçek faktörü ise uniform sayı üretici tarafından kontrol edilen gama dağılımına uygun rastgele sayı üretici tarafından elde edilir. Bu sayı üreticini çalışma aralığı [0 1]'dir. Ayrıca bu tip sayı üretici ile yapay superorganizmanın çok farklı doğrultularda hareket etmesi sağlanır. DS'de yeni bir konaklama alanı şu eşitlik kullanılarak hesaplanır(Civicioglu 2012):


$$StopoverSite = SuperOrganizm + ScaleFactor * (Donor - SuperOrganizm) \quad (11)$$

Diferansiyel Arama Algoritmasında Bijective DS, Surjective DS ve Elitist DS olmak üzere üç farklı konaklama alanı üretme mekanizması tanımlıdır. Bijective DS'de her klan farklı bir klana giderek habitatı araştırır. Bijective DS multi-modal problemlerin kullanımı için uygundur. Surjective DS'de bir klan daha verimli bir konumdaki klanlara doğru gitme eğilimi vardır. Kısmen multimodal ve daha çok unimodal problemler için tercih edilebilir. Elitist DS'de ise tüm klanları, en verimli lokasyondaki klana doğru gitmeye zorlar. Çok hızlı bir mekanizmadır ve özellikle unimodal problemler için kullanılabilir. Ek olarak DS algoritmasının içerisinde, ölçek faktörün üretilmesi için kullanılabilecek farklı sayı üreticileri tanımlanmıştır. Bu çalışmada ise  $normrnd(mu, sigma)$  sayı üretici tercih edilmiştir. Bu sayı üretici normal dağılıma uyan, ortalama ve standart sapma parametreleri sırasıyla  $\mu$  ve  $\sigma$  olan rastgele sayılar üretir.

Superorganizmayı oluşturan yapay organizmadaki bireylerden hangilerinin konaklama alanı arama sürecine katılacağı rastgele bir süreç sonunda karar verilir. Ek olarak DS'de yalnızca iki kontrol parametresi bulunur. Bunlar  $p1$  ve  $p2$ 'dir. Daha önceki yapılan testlerde  $p1$  ve  $p2$  için 0.3 önerilmiş ve bu proje kapsamında yapılan testler aynı değerin en başarılı sonuçları ürettiği gözlemlenmiştir.


### 3. VERİ SETLERİ VE DENEYSEL SONUÇLAR

Bu çalışmada sunulan yaklaşımın etkinliğini ortaya koymak için hem SAR hem de optik görüntü kullanılmıştır. . Optic görüntü seti Landsat 5 uydusundan temin edilmiş olan 1995 ve 1996 yıllarına ait Sardinia adasındaki Mulargia gölüne aittir. Görüntü çözünürlüğü ise 300x412 pikseldir. Ayrıca değişim belirleme işlemi için çok kanallı görüntünün 4. Bandı kullanılmıştır. Sardinia veri seti ve yer doğruluklu görüntü Şekil-1'de gösterilmiştir.



Şekil-1. Testlerde kullanılan Sardinia görüntüleri:(a) Eylül 1995. (b) Eylül 1996. (c) Yer Doğruluklu Görüntü.

SAR veri seti, European Remote Sensing (ERS)-2 uydusu tarafından alınmış olan Nisan ve Mayıs 1999 yıllarına ait Bern, İsviçre'deki bir bölgeye aittir. Görüntü 301x301 piksel çözünürlüğündedir. Bern veri seti ve yer doğruluklu görüntü Şekil-2'de sunulmuştur.




Şekil-2. Testlerde kullanılan Bern SAR görüntüleri: (a) Nisan 1999. (b) Mayıs 1999. (c) Yer Doğruluklu Görüntü.

Geliştirilen yaklaşımın kantitatif analizi için aşağıda tanımlanmış olan nicelikler kullanılmıştır.

1. **False Alarm(FA):** değişmiş olarak etiketlenmiş ancak gerçekte değişmemiş piksellerin sayısı
2. **Missed Alarms(MA):** değişmemiş olarak etiketlenmiş ancak gerçekte değişmiş piksellerin sayısı
3. **Total Error (TE):** yanlış etiketlenmiş piksellerin tamamı (FA+MA)
4. **Total Error Rate (TER):** TER yüzde olarak şu şekilde hesaplanır  
$$TER = (FA + MA) / (PN) \times 100$$
 burada  $PN$  is görüntüdeki tüm piksellerin sayısıdır.

İlk deneysel uygulamada, önerilen yaklaşım tek bantlı değişim belirleme çalışmalarında sıklıkla kullanılan ve oldukça başarılı yöntemlerden HCM, EM+MRF( $\beta=1.7$ ), SA\_HCM, G\_HCM, FCM, G\_FCM, PCA-Kmeans temelli yaklaşımlarla daha önceki çalışmalarda elde edilen sonuçlarla karşılaştırılmıştır. Böylelikle geliştirilen yaklaşımın optik görüntüler üzerinde etkinliği analiz edilmiştir. Uygulama sonucunda elde edilen görsel bulgular Şekil-3'de, hata değerleri ise Tablo-1'de sunulmuştur.




Şekil-3. Sonuçlar a)PCA-Kmeans. (b) Sunulan Yaklaşım. (c) Yer Doğruluklu Görüntü.

| Kullanılan Yöntem                            | False Alarm | Missed Alarm | Total Error | Total Error Rate |
|----------------------------------------------|-------------|--------------|-------------|------------------|
| HCM (Ghosh et al. 2011)                      | 275         | 4133         | 4408        | 3.56             |
| EM+MRF( $\beta=1.7$ )<br>(Patra et al. 2007) | 3856        | 289          | 4145        | 3.35             |
| SA_HCM (Ghosh et al. 2011)                   | 425         | 2727         | 3152        | 2.55             |
| G_HCM (Ghosh et al. 2011)                    | 3006        | 132          | 3138        | 2.53             |
| FCM (Ghosh et al. 2011)                      | 494         | 2246         | 2740        | 2.21             |
| G_FCM (Ghosh et al. 2011)                    | 627         | 1983         | 2610        | 2.11             |
| PCA-Kmeans (Celik 2009b)                     | 1603        | 832          | 2435        | 1.97             |
| <b>Sunulan Yaklaşım</b>                      | <b>744</b>  | <b>1405</b>  | <b>2159</b> | <b>1.73</b>      |

Tablo 1. Sardinia veri eti için yapılan deneysel çalışmanın kantitatif sonuçları

Optik görüntü üzerinde yapılan testlerde konaklama alanı üretme mekanizması olarak Bijective DS ölçek faktörü olarak  $R=1/normrnd(0,5)$  jenerasyon sayısı olarak 400 seçilmiştir. Şekil-3 ve Tablo 1 incelendiğinde sunulan DS tabanlı yaklaşımın karşılaştırılan diğer yöntemlere daha başarılı sonuçlar elde ettiği görülebilir.

İkinci deneysel uygulamada DS tabanlı yaklaşım, SAR görüntülerinden oluşan Bern veri setine uygulanmıştır. Böylelikle sunulan yaklaşımın hem optik görüntülerde hem de radar görüntülerinde etkinliği irdelenmiştir. Elde edilen görsel bulgular Şekil-4’de ve hata değerleri ise Tablo 2’de sunulmuştur. Bu uygulamada ise, elde edilen sonuçlar PCA-Kmeans, FCM, FLICM ve RFLICM temelli yöntemlerle kıyaslanmıştır.



Şekil 4. Sonuçlar. (a)PCA-Kmeans (b) Sunulan Yaklaşım. (c) Yer Doğruluklu Görüntü

SAR görüntüsü (Bern veri seti) üzerinde yapılan testlerde konaklama alanı üretme mekanizması olarak Elitist DS ölçek faktörü olarak  $R=1/normrnd(0,5)$  jenerasyon sayısı olarak 500 seçilmiştir. Şekil-4 ve Tablo 2 incelendiğinde sunulan DS tabanlı yaklaşımın oldukça başarılı sonuçlar elde ettiği gözlemlenmiştir

| <b>Kullanılan Yöntem</b>       | <b>False Alarm</b> | <b>Missed Alarm</b> | <b>Total Error</b> | <b>Total Error Rate</b> |
|--------------------------------|--------------------|---------------------|--------------------|-------------------------|
| FCM(Gong et al. 2012)          | 507                | 61                  | 568                | 0.626                   |
| FLICM(Gong et al. 2012)        | 137                | 169                 | 306                | 0.337                   |
| PCA-Kmeans Based (Celik 2009b) | 146                | 158                 | 304                | 0.335                   |
| RFLICM(Gong et al. 2012)       | 133                | 159                 | 292                | 0.322                   |
| <b>Sunulan Yaklaşım</b>        | <b>160</b>         | <b>133</b>          | <b>293</b>         | <b>0.323</b>            |

Tablo 2. Bern veri seti için yapılan deneysel çalışmanın kantitatif sonuçları

## SONUÇ

Bu çalışmada, uzaktan algılama görüntüleri için Diferansiyel Arama algoritması ve PCA tabanlı yeni bir değişim saptama yaklaşımı sunulmuştur. Yaklaşım fark görüntüsü  $k \times k$  bindirmesiz bloklara ayrılır PCA ile özellik uzayına dönüştürülür. Ardından bu özellik uzayına Min-Max normalizasyonu yapılır ve elde edilen veri seti Diferansiyel Arama Algoritması ile değişen ve değişmeyen alanlar olarak iki sınıfa ayrılır. Bu şekilde değişim haritası elde edilmiş olur. DS tabanlı yaklaşım birçok değişim saptama tekniği ile karşılaştırıldı. Bu deneysel çalışmalarda hem optik görüntü hem de SAR görüntüsü kullanılmıştır. Elde edilen bulgular neticesinde, sunulan yaklaşım hem optik görüntülerde hem de SAR görüntülerinde kontrolsüz değişim belirleme amacıyla kullanılabileceği ortaya konmuştur.

## KAYNAKLAR

- Bruzzone, L. and D. Prieto. 2000. Automatic analysis of the difference image for unsupervised change detection. *IEEE Transactions on Geoscience and Remote Sensing* 38(3):1171–1182. doi: 10.1109/36.843009
- Celik, T. 2009a. Multiscale Change Detection in Multitemporal Satellite Images. *IEEE Transactions on Geoscience and Remote Sensing Letters* 6( 4):820–824
- Celik, T. 2009b. Unsupervised Change Detection in Satellite Images Using Principal Component Analysis and k-Means Clustering. *IEEE Transactions on Geoscience and Remote Sensing Letters* 6(4):772-776 doi: 10.1109/LGRS.2009.2025059
- Celik, T., and K. K. Ma. 2011. Multitemporal Image Change Detection Using Undecimated Discrete Wavelet Transform and Active Contours. *IEEE Transactions on Geoscience and Remote Sensing* 49(2): 706-716.
- Cihlar, J., T. Pultz, and A. L. Gray. 1992. Change Detection with Synthetic Aperture Radar. *International Journal of Remote Sensing* 13: 401-414
- Civicioglu, P. 2012. Transforming Geocentric Cartesian Coordinates to Geodetic Coordinates by Using Differential Search Algorithm. *Computers and Geosciences* 46:229-247. doi:10.1016/j.cageo.2011.12.011.
- Ghosh, S., L. Bruzzone, S. Patra, F. Bovolo, A. Ghosh. 2007. A context-sensitive technique for unsupervised change detection based on Hopfield-type neural networks. *IEEE Transactions on Geoscience and Remote Sensing* 45: 778–789. doi: 10.1109/TGRS.2006.888861
- Ghosh, A., N. S. Mishra, and S. Ghosh. 2011. Fuzzy Clustering Algorithms for Unsupervised Change Detection in Remote Sensing Images. *Information Sciences* 181:699-715. doi:10.1016/j.ins.2010.10.016.
- Gong, M. G., Z. Q. Zhou, and J. J. Ma. 2012. Change Detection in Synthetic Aperture Radar Images based on Image Fusion and Fuzzy Clustering. *IEEE Transactions on Image Processing* 21(4):2141-2151. doi: 10.1109/TIP.2011.2170702
- Gopal, S., C. Woodcock. 1996. Remote Sensing Of Forest Change Using Artificial Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing* 34:398–404. doi: 10.1109/36.485117
- Hao, M., H. Zhang, W. Z. Shi, and K. Z. Deng. 2013. Unsupervised change detection using fuzzy c-means and MRF from remotely sensed images. *Remote Sensing Letters*, 4(12): 1185-1194.
- Karaboga, D., and C. Ozturk. 2011. A novel clustering approach: Artificial Bee Colony (ABC) algorithm. *Applied Soft Computing* 11(1): 652-657.
- Krinidis, S., and V. Chatzis. 2010. A robust fuzzy local information C-means clustering algorithm. *IEEE Transactions Image Processing* 19(5):1328 – 1337.
- Mishra, N. S., S. Ghosh, and A. Ghosh. 2012. Fuzzy clustering algorithms incorporating local information for change detection in remotely sensed images. *Applied Soft Computing* 12:2683-2692. doi: 10.1016/j.asoc.2012.03.060

- Pacifici, F., F. Del Frate, C. Solimini, and W. Emery. 2007. An innovative neural net method to detect temporal changes in high-resolution optical satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 45:2940–2952.
- Patra, S., S. Ghosh, A. Ghosh. 2007. Unsupervised Change Detection in Remote-Sensing Images Using Modified Self-Organizing Feature Map Neural Network. *Computing Theory and Applications ICCTA '07*. International Conference on, on page(s): 716 - 720
- Zou, W., Y. Zhu, H. Chen, X. Sui. 2010. A Clustering Approach Using Cooperative Artificial Bee Colony Algorithm. *Discrete Dynamics in Nature and Society* vol.2010. doi:10.1155/2010/459796