

Koşullu Rasgele Alanlarla Bağlamsal Hedef Tanıma

Contextual Object Recognition with Conditional Random Fields

Gülcan Can, Orhan Fırat, Fatoş T. Yarman Vural
Bilgisayar Mühendisliği Bölümü
Orta Doğu Teknik Üniversitesi
Ankara, Türkiye
{gulcan, orhan.firat, vural}@ceng.metu.edu.tr

Özetçe—Uydu görüntülerinde bağlamsal tutarlılık gösteren hedeflerin tanınması için koşullu rasgele alanlarla (KRA) bağlamsal ilişkilere göre sonuç çıkaran bir yöntem önerilmektedir. Öncelikle hedef için bağlam değişmezleri, seyrek oto-kodlayıcılarla belirlenmiştir. Bunlardan en çok yinelenen seçilerek nitelediği alan, KRA modelinde merkez düğüm olarak kullanılmıştır. Bu aday alanları doğrudan hedef olarak işaretlemek veya kural tabanlı yaklaşımlar kullanmak yanlış veya eksik bulgulara neden olmaktadır. Yıldız şeklinde tasarlanan KRA modelindeki diğer düğümler ise merkez düğümün nitelediği alanın çevresindeki doğal alan sınıfları olarak seçilmiştir. Bu sınıflar, destek vektör makinalarına (DVM) en tanımlayıcı ve ayırt edici öznelikleri beslenerek bölütlerin etiketlenmesi ardından, aynı etikete sahip olan alanların birleştirilmesiyle elde edilmiştir. Aynı öznelikler bu kez bu birleşmiş alanlardan çıkartılarak KRA'da düğüm potansiyeli olarak kullanılmıştır. KRA'da kenar potansiyelleri bağlamsal ayırt ediciliği getirmektedir ve birlikte rastlama sıklığıyla ifade edilmiştir. Her örnek için çevresinde var olan sınıflara göre değişken bir model oluşturulmasına ve her düğümü iki durumda (o sınıf ya da değil şeklinde) değerlendirmeye dikkat edilmiştir. Bu açıdan bakılınca, KRA ile bağlamsal etiket güncelleme yapılmaktadır. Önerilen yöntem, sabit eşik değerlerinden arındırılmasıyla ve bağlamsal değişmezliği eğitimsiz elde edilen özneliklere dayandırılmasıyla daha gürbüzdür ve kural tabanlı veya doğrudan bölütleme üzerine eğitimi sınıflamalara göre başarımı daha yüksektir.

Anahtar Kelimeler —koşullu rasgele alanlar; bağlamsal değişmezlik; seyrek oto-kodlayıcılar; nesne tanıma; çok banlı uydu görüntüsü.

Abstract—For contextually consistent target recognition in satellite imagery, a contextual conditional random field (CRF) model is proposed. First of all, context invariance for the target is determined by sparse auto-encoders. The area represented by the most repetitive invariance is used as central node in CRF model. Marking such an area directly as the target or applying a rule-based methodology concludes in false alarms or missing results. Therefore, a star-shaped CRF, which models contextual relationships, is used. Other nodes of the CRF are chosen as land-use land-cover classes in the surroundings of the candidate target area. These classes are obtained by merging segments with the same label after feeding best known discriminative features to support vector machines. The same features are extracted from the merged class areas to be used as node features in CRF. Edge

features in CRF are essential for representing contextual relations and they are chosen as class co-occurrence frequencies. For each target candidate, a dynamic CRF model is generated and in those models, each node can have two states (true or false). The proposed method is robust in terms of being threshold-free and selecting contextual invariance via sparse auto-encoders. Performance of the method is competitive to rule-based methods and segmentation-based classification methods.

Keywords — conditional random fields; contextual invariance; sparse auto-encoders; object recognition; multispectral satellite imagery

I. GİRİŞ

Uzaktan algılama görüntülerinde, sınıf-içi değişinti çok fazla olduğu için nesnelere sadece görünüşlerine göre sınıflamak yetersiz kalabilmektedir. Örneğin; havaalanları tamamen farklı renkte, şekilde ve kompozisyonlarda gözlenebilir (bkz. Şekil 1). Bu sınıf-içi aşırı değişintiyle başa çıkabilmek için, bağlamsal modellerin temsil gücünden faydalanılabilir. Böylelikle, sadece görünüme bağlı alt-seviye ipuçlarından ziyade üst-seviye bağlamsal ilişkiler de kullanılarak daha doğru bir sınıflama yapılabilir. Havaalanı örneğinde bağlamsal ilişkiler, alan uzmanları tarafından, çevresindeki doğal alan sınıflarının belirli bir orandan az olması gibi kurallarla tanımlanabilir. Örneğin; pist kalkış istikametinde orman bulunmaması veya havaalanı etrafında %30'dan az yerleşim alanı bulunması. Ancak bu bağlamsal ilişkileri doğrudan kural tabanlı yaklaşımlarla uygulamak, sahada görülebilen örnekleri kaçırmaya neden olabilmektedir. Bu nedenle, bu çalışmada, bağlamsal ilişkileri modellemek için en gelişmiş tekniklerden olan olasılıksal grafik modellerin bir örneği kullanılmıştır [1]; koşullu rasgele alanlar (KRA) [2]. KRA, klasik sınıflayıcılar gibi "bağımsız ve eş dağılım" varsayımı yapmadığı için, gözlemler ve etiketler arası etkileşimin oldukça sık görüldüğü uydu görüntüleri gibi uzamsal verileri sınıflamak için oldukça uygundur. Bu sebeptendir ki KRA modeli, uzaktan algılama literatüründe, son zamanlarda pek çok çalışmada yerini almıştır [3-9].

Uzamsal yapıları modelleyen çalışmalar, gerek gösterimler açısından gerek de öğrenme yaklaşımları açısından çeşitlilik göstermektedir. [10]'da nesne tanıma için hiyerarşik KRA'lardan oluşan bir model önerilmiştir.



Şekil 1. Uydu görüntülerinden havaalanı örnekleri

En alt seviyedeki KRA pikseller üzerine, orta seviyedeki KRA bölütler üzerine ve en üst seviyedeki KRA ise nesnel üzerine kuruludur. Çıkarım adımında, tüm bu seviyeler içindeki ve arasındaki etkileşimler dikkate alınır. Jiang. ve diğerleri tarafından önerilen *bağlama dayalı kavram kaynaştırma* modelindeyse bir kaç sınıflayıcıdan çıkan sonsal olasılıklar, her düğümü bir kavramı ifade eden tam bağlantılı KRA'ya beslenir ve güncellenmiş olasılık değerleri elde edilir [11]. Lee ve diğerleri *destek vektör rasgele alanları* adını verdikleri, destek vektör makinalarının (DVM) genelleme özelliği ile KRA'ların farklı uzamsal bağımlılıkları modelleyebilme özelliklerini birleştiren bir model önermişlerdir [12]. KRA'daki düğüm potansiyeli olarak destek vektör makinasındaki ayırt edici düzleme uzaklıklar kullanılmıştır.

Bu çalışmada, bağlamsal tutarlılık gösteren bir hedefi tanımak amacıyla, çevresindeki diğer sınıflarla bağlamsal ilişkileri yıldız şeklinde bir KRA modeliyle ifade edilmiştir. KRA modelinin oluşturulması esnasında [9]'daki kavramlar üzerine kurulu modelden esinlenilmiştir. Ancak modelin gösterimsel gücünü artırmak amacıyla, [9]'daki tam bağlantılı model yerine, yıldız modele geçilmiştir ve asıl ilgilenilen hedef merkez düğümüne konuşturulmuştur. Diğer sınıflar ise çevre düğümlere yerleştirilmiştir. Diğer sınıf düğümlerinin karşılık geldiği alanlar belirlenirken, her ne kadar herhangi bir sınıflayıcı kullanılabilecek olsa da [10]'daki gibi DVM'in gücünden faydalanılmak istenmiş ve etiketleme çıktılarından aynı olanlar birleştirilmiştir. Ancak, önerilen model [10]'dan ziyade [9] ile örtüşmektedir. Ayrıca doğrudan bölütler veya pikseller üzerine rasgele alanları kurmadığı ve onun yerine kavramlar üzerine kurduğu için modeli oldukça basitleştirerek [8] ve benzeri çalışmalardan ayrılır. Önerilen modelin amacı, merkez düğümdeki aday alanın, çevredeki diğer sınıflarla olan bağlamsal ilişkilerine göre, hedef olup olmadığı çıkarımında bulunmaktır.

Bildirinin geri kalanı şu şekilde düzenlenmiştir: ikinci bölümde koşullu rasgele alanlarla ilgili teorik bilgiler sunulmuştur, üçüncü bölümde bağlamsal değişmezlik tanımlanmıştır, dördüncü bölümde seyrek oto-kodlayıcılarla ilgili teorik bilgilere yer verilmiştir, dördüncü bölümde önerilen algoritma ayrıntılandırılmıştır, beşinci bölümde deney aşamasından bahsedilmiştir ve son bölümde deney sonuçları değerlendirilmiştir.

II. KOŞULLU RASGELE ALANLAR

Koşullu rasgele alanlar, Lafferty'nin metin dizilerini analizleyen tek boyutlu modelinin, Kumar ve Hebert tarafından

iki boyutlu görüntülere uygulanmasıyla bilgisayarla görü camiasına tanıtılmıştır [2, 14]. KRA, $P(y|x)$ sonsal olasılık dağılımını bir Gibbs alanı olarak doğrudan modeller. Böylelikle, önsel veya ortak dağılım ne denli karmaşık olursa olsun, onlar modellenmeye uğraşmadan, verideki gelişigüzel bağımlılıklar model yaklaşımlarına gerek duyulmadan ifade edilmiş olur. Girdi görüntüdeki gözlenen veriye, i 'nci alandaki veri x_i olacak şekilde, $\mathbf{x} = \{x_i\}_{i \in S}$ diyelim. Bunlara ait etiketler de $\mathbf{y} = \{y_i\}_{i \in S}$ olsun. Bu çalışmada, aday bölgelerin sadece doğru bulunup bulunmadığıyla ilgilenildiği için $y_i \in \{0, 1\}$ olarak alınmıştır. KRA, düğümleri \mathbf{y} ile indekslenen $G = (S, E)$ çizgesinde, eğer \mathbf{x} üzerine koşullandırıldığında x_i rasgele değişkenleri, çizgeye göre Markov özelliğine uyuyorsa, (\mathbf{x}, \mathbf{y}) koşullu rasgele alan olarak tanımlanır. Markov özellik, $S - \{i\}$ çizgedeki i düğümü dışındaki tüm düğümleri gösterirken ve N_i ise çizgedeki i düğümünün tüm komşularına karşılık gelirken, $P(y_i | \mathbf{x}, \mathbf{y}_{S - \{i\}}) = P(y_i | \mathbf{x}, \mathbf{y}_{N_i})$ eşitliğinin sağlanmasıdır. Hammersley-Clifford teoremi kullanılarak ve ikililerden daha büyük klikleri göz ardı ederek \mathbf{x} gözlemleri üzerine \mathbf{y} etiketlerinin dağılımı aşağıdaki gibi ifade edilebilir:

$$P(\mathbf{y} | \mathbf{x}) = \frac{1}{Z} \exp\left(\sum_{i \in S} A_i(y_i, \mathbf{x}) + \sum_{i \in S} \sum_{j \in N_i} I_{ij}(y_i, y_j, \mathbf{x})\right) \quad (1)$$

Z düzleme sabiti olup A_i ve I_{ij} sırasıyla tekli (ilişkililik) ve ikili (etkileşim) potansiyelleri ifade eder.

A. İlişkililik Potansiyeli

İlişkililik potansiyeli, i 'nci alanın \mathbf{x} verildiğinde, y_i etiketine atanma olasılığını ölçer. Diyelim ki $\mathbf{f}(\cdot)$ fonksiyonu, görüntüde, çizgedeki bir düğümüne karşılık gelen bir alandan çıkarılmış öznelik vektörünü temsil etsin. Bu çalışmada öznelik vektöründen o alanın hangi sınıfa ait olduğuna dair potansiyel bilgisine geçmek için lojistik fonksiyon kullanılmıştır. Bu durumda, \mathbf{w} ağırlık parametre vektörünü gösterirken, ilişkililik potansiyeli aşağıdaki formu alır.

$$A(y_i, \mathbf{x}) = \log P'(y_i | \mathbf{f}_i(\mathbf{x})) = \log\left(\sigma(y_i \mathbf{w}^T \mathbf{f}_i(\mathbf{x}))\right) \quad (2)$$

B. Etkileşim Potansiyeli

Etkileşim potansiyeli, komşu olan i ve j alanlarının etiketlerinin \mathbf{x} verildiğinde birbirlerini nasıl etkilediğini ölçer ve aşağıdaki şekilde formüle dökülebilir.

$$I(y_i, y_j, \mathbf{x}) = \beta \left(K y_i y_j + (1 - K) \sigma(y_i y_j \mathbf{v}^T \boldsymbol{\mu}_{ij}(\mathbf{x})) \right) \quad (3)$$

İki komşu alan arasındaki kenar özneliklerini potansiyele çevirirken yine lojistik fonksiyon kullanılmıştır. β yumuşatma derecesini belirleyen parametredir. K ise eğitme verisine göre komşu alanlara aynı etiketi atamaya çalışma ile veriye bağlı farklı etiketleri alabilme durumlarının maliyet fonksiyonuna katkılarının oranını belirler. $\boldsymbol{\mu}(\cdot)$ ve \mathbf{v} sırasıyla (2)'deki $\mathbf{f}(\cdot)$ ve \mathbf{w} ile denktir.

III. BAĞLAM DEĞİŞMEZLİĞİ

Bağlam değişmezliği, [13]'te tanımlandığı üzere, "aranan nesnenin bağlamsal olarak tanımlanmış tüm dönüşümler altında değişmeyen bir niteliğine" karşılık gelmektedir. Havalimanı örneği için, en az bir pist içermesi bir bağlam değişmezi olarak düşünülebilir. Bu değişimleri alan uzmanlarıyla çalışarak belirlemek mümkün olsa da bu durum eğitmesiz metotlar kullanılmasını zora sokmaktadır. Bu

çalışmada, bağlam değişmezliği otomatik olarak seyrek oto-kodlayıcılarla verisetinden belirlenmiştir.

IV. SEYREK OTO-KODLAYICILAR

Oto-kodlayıcılar temelde, öğreticisiz geri-yayılım (backpropagation) uygulayan yapay-sinir ağı olup [16] çıktı nöronları olarak girdi nöronlarını kestirmeye çalışırlar. Gizli nöronların seyreklikleri (sıfıra yakın aktivasyon) ayarlanarak, girdisini en kompakt şekilde ifade etmek üzere optimize edilirler. Bu maksatla, verisetini girdi olarak alıp, çıktı olarak da $\varphi: \mathbb{R}^N \rightarrow \mathbb{R}^K$ olan bir eşleme-fonksiyonu verirler. Burada φ , N boyutlu bir girdi vektörünü x , K boyutlu yeni bir öznitelik uzayına eşlemektedir. K kullanıcı tarafından belirlenen bir parametre olup oto-kodlayıcının gizli katmanındaki nöron sayısını belirlemektedir. Eşleme fonksiyonu φ verisetini en etkin betimleyen öznitelikleri ortaya çıkarmakta olup, Şekil 3'te görüldüğü üzere pist bölgelerinde eğitilen oto-kodlayıcı için farklı yönelimlerdeki paralel çizgileri çıkartmaktadır.

Bu çalışmada K adet gizli nöronu olan bir oto-kodlayıcı, yeniden inşa etme hatasının karesini minimize etmek üzere geri-yayılım algoritması ile eğitilmiştir. Eğitim için ceza fonksiyonuna, gizli düğümlerde düşük ortalama aktivasyonu sağlamak maksadıyla ek bir ceza bileşeni koyulmuştur.

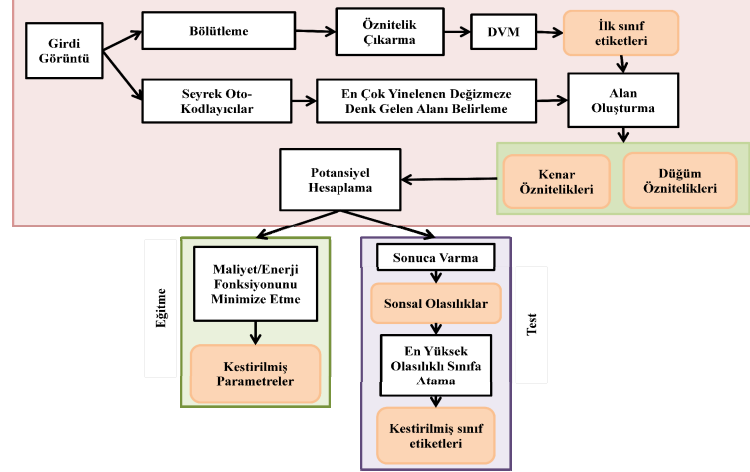
$$J_{seyrek}(W, b) = J(W, b) + \delta \sum_{j=1}^K \text{KL}(\rho || \hat{\rho}_j) \quad (4)$$

Optimizasyon için kullanılan ceza fonksiyonu (4) ilk terim olarak tek-seviyeli standart yapay-sinir ağı ceza terimini $J(W, b)$, ikinci terim olarak da seyreklik ceza terimini içermektedir. Algoritma parametresi olan δ , seyreklik ceza teriminin ağırlığını belirlemekte olup; $\text{KL}(\rho || \hat{\rho}_j)$ ortalaması ρ olan bir Bernoulli rastgele değişken ile ortalaması $\hat{\rho}_j$ olan bir Bernoulli rastgele değişken arasındaki Kullback-Leibler uyumsuzluğudur. Algoritma seyreklik parametresi olan ρ genellikle sıfıra yakın bir değer olarak seçilmektedir. Seyrek oto-kodlayıcının girdisi x kullanılan j 'inci gizli nöron olmak üzere, $\hat{\rho}_j$ bu nörona ait (tüm veri-seti üzerinden) ortalama aktivasyonu ifade etmektedir. Sonuçta seyrek oto-kodlayıcı algoritması çıktı olarak, geçiş ağırlıkları $W \in \mathbb{R}^{K \times N}$ ile yanlılık ağırlıkları $b \in \mathbb{R}^K$ vermekte ve öznitelik eşleme fonksiyonu $\varphi(x) = \sigma(Wx + b)$ şeklinde tanımlanmaktadır. Burada $\sigma(z) = 1/(1 + \exp(-z))$ sigmoid fonksiyonudur.

V. ÖNERİLEN ALGORİTMA

Bu çalışmada, bağlamsal tutarlılık gösteren hedeflerin tespiti için iki aşamalı bir yöntem önerilmektedir. Öncelikle, hedefi betimleyen bağlam değişmezi seyrek oto-kodlayıcılarla belirlenmektedir. Havaalanı hedefi için seyrek oto-kodlayıcılardan alınan betimlemeler Şekil 3'te incelenebilir. Dikkat edileceği üzere, havaalanını en iyi betimleyen parçalar, paralel çizgiler, pist başı işaretleri ve uçakların teker izleri olmuştur. Bunlardan en çok yineleneni, daha önce alan uzmanları tarafından belirtilip [13]'te de kullanıldığı üzere, paralel çizgilerdir ve bu çalışmada koşullu rasgele alanın merkez düğümüne, havaalanı aday bölgesini temsil edecek


şekilde, bu paralel çizgilerle sınırlı bölgeler (PÇSB) konulmuştur.



Şekil 2. Algoritma Akış Şeması

Yıldız şeklinde tasarlanan KRA modelindeki diğer düğümler ise merkez düğümün nitelediği alanın çevresindeki doğal alan sınıfları olarak seçilmiştir. Öncelikle, bu sınıfları en tanımlayan ve ayırt eden öznitelikler, destek vektör makinalarına (DVM) verilerek bölütler etiketlenmiştir. Ardından, aynı etikete sahip olan alanların birleştirilmesiyle KRA modelindeki düğümlere karşılık gelen alanlar (orman, su, yeşil alan, yerleşim alanı, toprak, beton) elde edilmiştir. Aynı öznitelikler bu kez bu birleşmiş alanlardan çıkartılarak KRA'da düğüm potansiyeli olarak kullanılmıştır. Bu öznitelikler, normalize fark su indisi [15], normalize fark bitki örtüsü indisi, Gabor filtre tepkileri, spektral değerler ve sayısal yükselti haritasının ilgili bölgesindeki standart sapmasıdır. Kenar potansiyellerini oluşturmak için ise bu birleşmiş alanlarla merkez düğümün bağlamsal etkileşimini betimleyen öznitelik fonksiyonları kullanılmıştır. Bu öznitelik fonksiyonları, çakışma, komşuluk ve yakınında rastlanma sıklığı olarak seçilmiştir. Algoritma genel akış şeması Şekil 2 ile sunulmuştur.

Önerilen KRA enerji fonksiyonunun negatif logaritması (ceza fonksiyonu) dışbükey optimizasyon teknikleri ile çözümlenerek model parametreleri $\theta = \{w, v\}$ öğrenilir. Ceza fonksiyonunun optimizasyonu için L-BFGS metodu kullanılmış olup [17], parametreler L2 düzenleştirmeye tabi tutulmuştur. Modelin basitliği, eğitim ve test aşamalarında çıkarım adımı için *kesin çıkarım* metodu kullanılmasına olanak sağlamıştır.



Şekil 3. Havaalanı hedefi için seyrek oto-kodlayıcılardan alınan betimleme

VI. DENEYLER

Bu çalışmada, yaklaşık 3800'e 3800 piksellik 4 adet GEOEYE görüntüsü kullanılmıştır. Verisetinde toplam 198 PÇSB bulunmaktadır. Verisetinin %80'i eğitime için, kalan %20'si ise test için kullanılmıştır. Bu işlem beş kez tekrarlanarak başarımın ortalaması, (5)'e göre belirlenmiştir. Bu değerler, Tablo 1'de incelenebilir. Seyrek oto-kodlayıcı eğitmek amacıyla, verisetindeki görüntüler tek banda indirgenerek çıkarılan alt-parçalar kontrast normalizasyonuna tabi tutulmuştur. Betimleme sayısı (oto-kodlayıcı gizli nöron) 100 olarak sabitlenmiştir. Alış alanı olarak da adlandırılan betimleme boyutu 28x28 piksel olarak seçilmiş ve seyrek oto-kodlayıcı verisetinden bu boyutta rastgele seçilen parçalarla eğitilerek parametreleri öğrenilmiştir.

$$\text{Kesinlik} = \frac{DB}{DB+YB} \quad \text{Geri Getirme} = \frac{DB}{DB+YE} \quad F_{\text{Skor}} = 2 * \frac{K*G}{K+G} \quad (5)$$

DB: Doğru Bulunan YB: Yanlış Bulunan YE: Yanlış Eksik K: Kesinlik G: Geri Getirme

TABLO I. ALGORİTMA KARŞILAŞTIRMALARI

Kullanılan Yöntem	Başarım Ölçütü		
	Geri getirme	Kesinlik	F-Skor
Kural tabanlı yaklaşım [13]*	%75	%85	%79.69
Tam bağlantılı KRA modeli [9]	%57.14	%93.33	%70.88
Önerilen yaklaşım	%91.30	%86.10	%88.63

* Öğreticisiz bir yöntem olduğundan veri seti farklılık göstermektedir.

VII. SONUÇ VE DEĞERLENDİRME

Tam bağlantılı KRA modeline [9] göre, bu çalışmada önerilen model her aday PÇSB örneğine göre değişebilecek şekilde dinamikleştirilmiştir. Örneğin, bir PÇSB etrafında su ve orman sınıflarına ait bölge yoksa oluşturulan KRA modelinde su ve orman düğümleri yer almamaktadır. Bu değişiklik, eğitim sırasında karşılaşılan hataları, ceza fonksiyonunun gereksiz büyümesi gibi, elemiş olur. Bir diğer iyileştirme ise her bir düğüm için atanacak sınıf sayısının ikiye (o sınıf veya değil şeklinde) indirilmesidir. Böylece sonsal olasılık dağılımı seyrekleşmeyip daha anlamlı bir etiketleme elde edilebilmiştir. Son olarak da tam bağlı modelden yıldız modele geçilmesiyle, etkileşim sadece PÇSB aday alanları üzerinden gerçekleşmektedir. Kaldırılan kenarlar sayesinde, kenar ağırlıklarına ait parametre sayısı azaltılıp aynı veri setiyle daha etkin bir parametre öğrenmesi yapılmıştır. Bu etkenler önerilen algoritmanın başarımını önceki modellere göre %10-20 arasında iyileştirmiştir (Tablo I).

Bu çalışmada, uydu görüntülerinde hedef tanımak için koşullu rasgele alanlarla (KRA) bağlamsal ilişkilere göre sonuç çıkaran bir yöntem önerilmiştir. Bağlamsal değişmezler seyrek oto-kodlayıcı vasıtasıyla öğrenilmiştir ve bu değişmezler üzerinde kurulan KRA özgün bir model olup, yalnızca uydu görüntülerinde değil bağlamsal tutarlılık gösteren her tür alanda uygulanabilir.

KAYNAKÇA

[1] Galleguillos, C. & Belongie, S., "Context based object categorization: A critical survey", *Computer Vision and Image Understanding*, Vol. 114, 2010, p 712-722.

[2] Lafferty J. D., McCallum A., and Pereira F. C. N., "Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data", *Proceedings of the Eighteenth International Conference on Machine Learning*, 282-289, 2001.

[3] Benedek, C. & Sziranyi, T. Change Detection in Optical Aerial Images by a Multilayer Conditional Mixed Markov Model. *IEEE Trans. on Geoscience and Remote Sensing Proc.*, 47:3416-3430, 2009.

[4] Zhong, P. & Wang, R. Learning conditional random fields for classification of hyperspectral images. *IEEE Trans. on Image Processing Proc.*, 19:1890-907, 2010.

[5] Roscher, R., Waske, B., Fořstner, W., "Kernel Discriminative Random Fields for land cover classification," *Pattern Recognition in Remote Sensing, 2010 IAPR Workshop on*, 1-5, 2010.

[6] Li, Z., Ma, J., Zhang, R., Chen, X., "Urban areas detection based on conditional random field and multiscale textural features", *SPIE Remote Sensing and GIS Data Processing and Other Applications Proc.*, 74981I, 2009.

[7] Besbes O., Boujemaa N., Belhadj Z., "Cue Integration for Urban Area Extraction in Remote Sensing Images", *Image Analysis and Recognition, Lecture Notes in Computer Science*, Vol. 5627, 2009, p 248-257.

[8] Hoberg, T. and Rottensteiner, F., "Classification of settlement areas in remote sensing imagery using conditional random fields," *ISPRS TC VII Symposium-100 Years ISPRS*, 2010.

[9] Can G., Firat O., Yarman Vural F.T., "Conditional Random Fields for Land Use/Land Cover Classification and Complex Region Detection", *Structural, Syntactic, and Statistical Pattern Recognition, Lecture Notes in Computer Science*, Vol. 7626, 2012, p 216-224.

[10] Gould, S. *Probabilistic models for region-based scene understanding*, 2010.

[11] Jiang, W., Chang, S.-F. & Loui, A.C., "Context-Based Concept Fusion with Boosted Conditional Random Fields", *IEEE International Conference on Acoustics, Speech and Signal Processing Proc.*, 1:949-952, 2007.

[12] Lee, C.H., Greiner, R. & Schmidt, M., "Support vector random fields for spatial classification", *PKDD Proc.*, 121-132, 2005.

[13] Firat, O., Tursun, O.T. & Yarman Vural, F.T. Application of Context Invariants in Airport Region of Interest Detection for Multi-spectral Satellite Imagery. *IEEE 20th Conference on Signal Processing and Communications Applications Proc.*, 2012.

[14] Kumar S. and Hebert M., "Discriminative Random Fields: A Discriminative Framework for Contextual Interaction in Classification", *IEEE International Conference on Computer Vision Proc.*, 2003.

[15] McFeeters, S.K. The use of the Normalized Difference Water Index (NDWI) in the de-lineation of open water features. *International Journal of Remote Sensing*, Vol.17, 1996, p 1425-1432.

[16] Bengio, Y., LeCun, Y., "Scaling learning algorithms towards AI," *Large-Scale Kernel Machines*, 2007.

[17] Byrd, R. H., Nocedal, J., and Schnabel, R. B., "Representations of quasi-Newton matrices and their use in limited memory methods," *Mathematical Programming*, Vol. 63, No. 1-3, 1994, p 129-156.