

TARIMSAL ÜRÜN SINIFLANDIRMADA ÇİZGE-TABANLI YÖNTEM: YENİ BİR YAKLAŞIM

A. Özdarıcı Ok^{a,*}, A. Ö. Ok^b

^a Yüzüncü Yıl Üniversitesi, Mühendislik-Mimarlık Fakültesi, Şehir ve Bölge Planlama Bölümü, 65080, Van, Türkiye
aozdarici@gmail.com

^b Mersin Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, 33343, Mersin, Türkiye
oozgun@mersin.edu.tr

Komisyon VII, WG VII/4

ANAHTAR SÖZCÜKLER: Ürün Sınıflandırma, Çizge-tabanlı Yöntem, Tarım, Uydu Görüntüleri

ÖZET:

Bu çalışmada, yüksek çözünürlüklü uydu görüntülerinden tarımsal ürünlerin sınıflandırılması amacıyla Çizge-tabanlı bir yöntem önerilmektedir. Yöntemde düğümleri temel nesnelere (piksellere) karşılık gelen bir çizge oluşturulmakta ve birbiriyle ilişkili nesnelere bu çizgede kenarlarla birleştirilmektedir. Bu sayede görüntü bir çizge olarak tanımlanmakta ve sınıflama bu çizge üzerinde gerçekleştirilmektedir. Sınıflama sırasında çizgedeki her bir düğüme karşılık gelen maliyet değerlerinin hesaplanması için toplanan örnek alanlara ait piksellerin spektral yansıma değerleri dikkate alınmış ve istatistikte verinin bir veya daha fazla gauss dağılımı ile gösterilmesine dayanan gauss karışım modeli kullanılmıştır. Devamında birbirleriyle komşu olan pikseller arasında oluşturulan kenarlara ağırlıklar atanmıştır. Ağırlık ataması sırasında komşu pikseller arasındaki mekânsal ve spektral mesafeyi dikkate alan üstel bir fonksiyon kullanılmış ve bu sayede pikseller arasındaki mekânsal komşuluk ilişkileri kullanılarak sınıflandırma sırasında düzleştirme sağlanmıştır. Sınıflandırma için maliyet ve düzleştirme etkileri aynı anda dikkate alınarak çok-sınıflı bir optimizasyon yöntemi olan α -açılımı yöntemi kullanılmış ve bu sayede Çizge-tabanlı sınıflama sonucu elde edilmiştir. Analizler, Bursa ilinin Karacabey Ovası'nın yaklaşık 100 km² lik bir bölümü kapsayan farklı tarihlerde çekilmiş 4 bantlı IKONOS ve Kompsat-2 uydu görüntüleri üzerinde gerçekleştirilmiştir. Sınıflama sonucunda elde edilen tematik haritalara ait genel doğruluk, kappa istatistiği ve ürün sınıflarına ait üretici ve kullanıcı doğrulukları piksel ölçeğinde hesaplanmıştır. Elde edilen sonuçlara göre önerilen Çizge-tabanlı yaklaşım, IKONOS ve Kompsat-2 görüntüleri için sırasıyla %82.36 ve %89.32 genel doğruluk seviyelerine ulaşmıştır. Ulaşılan bu doğruluk seviyelerinin değerlendirilmesi amacıyla güvenilirliği kanıtlanmış bir yöntem olan Destek Vektör Makineleri (DVM) de ayrıca görüntüye uygulanmış ve elde edilen sonuçlar Çizge-tabanlı yöntem sonuçlarıyla karşılaştırılmıştır. Elde edilen sonuçlar önerilen yaklaşımın DVM yöntemine göre daha güvenilir sonuçlar ürettiğini ve bu yöntemin kullanılmasıyla üretilecek tematik haritaların tarımsal kararların alınmasında ve sürdürülebilirliğin sağlanmasında önemli bir rol üstlenebileceğini ortaya koymuştur.

1. GİRİŞ

Gözlem uyduları tarafından çekilen görüntülerin yeryüzünde hangi arazi örtüsü veya kullanımını içerdiğine ilişkin soru günümüzde uzaktan algılama ve görüntü işleme alanında çalışan araştırmacıların yakından ilgilendiği başlıca konulardan birisidir. Bu konu kapsamında kullanılan en yaygın yöntem görüntü sınıflandırmasıdır. Günümüze kadar geliştirilen sınıflandırma algoritmalarının önemli bir kısmı, daha güvenilir haritalar üretmesi nedeniyle arazi örtüsü veya kullanımını belirten sınıf bilgilerinin bilgisayar ortamında bir kullanıcı tarafından önceden tanımlanmasını, başka bir deyişle kontrollü sınıflandırılmasını içermektedir. Kontrollü sınıflandırma için önerilen yöntemlerin hemen hemen hepsi sınıflandırma sırasında görüntüyü oluşturan pikselleri birbirinden bağımsız olarak ele almakta ve çoğunlukla piksellerin spektral yansıma değerlerine bağlı kalan istatistiksel yöntemlere dayalı algoritmalar yardımıyla önceden belirlenmiş arazi sınıflarına göre etiketleme yapmaktadır. Bu amaçla geliştirilen algoritmalar arasında en popüler olanı istatistiğe dayalı En Çok Benzerlik yöntemidir. En Çok Benzerlik yönteminde görüntüyü oluşturan piksellerin spektral değerlerine bağlı olarak kullanıcı tarafından tanımlanmış sınıf etiketlerine atanır. Bu işlem verideki piksellerin normal dağılıma sahip olduğu varsayımına dayanır (Lillesand, 2005). Son yıllarda uydu görüntülerinden daha güvenilir sonuçlar üretilebilme amacıyla öğrenme tabanlı algoritmalar geliştirilmiştir. Bu algoritmaların en çok

kullanılanları arasında Destek Vektör Makineleri (DVM), Karar Ağaçları, Yapay Sinir Ağları, Rastgele Orman ve k-En Yakın Komşuluk yöntemleri gelmektedir. Bu yöntemler genel olarak makine öğrenme yöntemleri olarak adlandırılırlar ve istatistik tabanlı yöntemlerin aksine verinin herhangi bir dağılıma sahip olduğu varsayımına dayanmadan işlem yaparlar. Makine öğrenme yöntemleri, yeterli miktarda veri seti ve parametre kullanarak otomatik olarak kuralları tanımlamak ve bu sayede yeni oluşturulacak veri için en uygun model üretme mantığına dayanır [Breiman, 2001; Horning, 2010]. Yapılan çalışmalar, istatistiksel ve makine öğrenmesi tabanlı yöntemler kullanılarak güvenilir sonuçlar elde edildiğini göstermiştir (Prasad et al., 2006; Jay et al., 2009; Waske and Braun, 2009). Buna karşın tanımlanan yöntemler genelde veriye ait spektral değerleri kullanmakta ve mekânsal bilgi göz ardı edilmektedir.

Bu çalışmada kontrollü bir sınıflandırma yöntemi olarak uzaktan algılama çalışmalarındaki varlığı yeni olan Çizge-Tabanlı bir yöntem geliştirilmiş ve bu yöntemin performansı bir tarım alanı (Karacabey Ovası, Bursa) üzerinde yetiştirilen 6 farklı ürün türü için test edilmiştir. Geliştirilen yöntem uzaktan algılama çalışmalarında sıkça tercih edilen En Büyük Benzerlik, Destek Vektör Makineleri (DVM), Rastgele Orman vb. popüler yöntemlerden farklı olarak sınıflandırma sırasında pikseller arası mekânsal komşuluk etkileşimlerini dikkate almakta ve bu etkileşimleri kullanarak sınıflandırma doğruluklarını arttırmayı hedeflemektedir. Bu özelliği sayesinde önerilen yöntem

pikselleri birbirinden bağımsız olarak ele almamakta, görüntüdeki piksel komşuluk ilişkilerini dikkate alarak sınıflandırmayı tüm görüntü üzerinde global olarak gerçekleştiren bir yöntem olmaktadır. Geliştirilen yöntemin test aşamasında Karacabey Ovası'na ait sırasıyla 15 Temmuz 2004 ve 11 Temmuz 2008 tarihli çok-bantlı IKONOS ve Kompsat-2 uydu görüntüleri (4m) temin edilmiştir. Görüntüleri analizlere hazırlamak için gerekli ön işlemler gerçekleştirildikten sonra görüntüler geliştirilen Çizge-tabanlı yöntem yardımıyla sınıflandırılmıştır. Elde edilen tematik haritalar hata matrisleri yoluyla değerlendirilmiş ve görüntüler geleneksel DVM yöntemiyle de sınıflandırılarak önerilen yöntemin güvenilirliği test edilmiştir. Elde edilen sonuçlar incelendiğinde her iki görüntü için de Çizge-tabanlı yöntemin daha güvenilir tematik haritalar ürettiği ortaya çıkmıştır.

Çalışmanın işlem adımları metnin ilerleyen bölümlerinde detaylı olarak açıklanmaktadır. Buna göre; Bölüm 2'de çalışma alanı ve kullanılan veri seti tanımlanmıştır. Bölüm 3'te geliştirilen Çizge Tabanlı yöntem ve DVM yöntemi açıklanmış ve doğruluk analizlerinde kullanılan yöntem verilmiştir. 4. bölümde sınıflandırmalar sonucunda elde edilen bulgular tartışılmış, son bölüm olan 5. bölümde ise çalışmadan elde edilen sonuçlar ortaya konulmuştur.

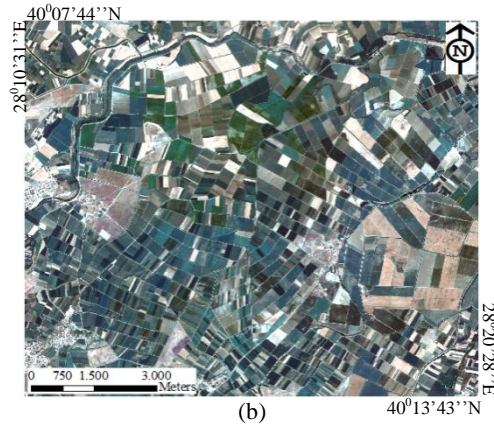

2. ÇALIŞMA ALANI VE VERİ SETİ

2.1 Çalışma Alanı

Çalışma alanı olarak Türkiye'nin kuzey-batısında yer alan Bursa ilindeki Karacabey Ovası'nın yaklaşık 100 km² lik bölümü seçilmiştir (merkez koordinatları: Boylam 28°14'12'' ve Enlem 40°11'09''). Alan, zengin toprak yapısı ve uygun hava koşulları nedeniyle Türkiye'nin en verimli ovaları arasındaki yerini almaktadır. Alana ait yıllık ortalama sıcaklık 14.4°C ve yıllık ortalama yağış miktarı 706 mm'dir. Alanın deniz seviyesinden yüksekliği yaklaşık 10 metredir. Çalışma alanında yetiştirilen başlıca tarım ürünleri; mısır, domates, buğday, pirinç ve şeker pancarıdır. Test alanı ayrıca, çiftlik hayvanlarına yem sağlamak amacıyla mera alanları da içermektedir (Turker ve Ozdarici, 2011).

2.2 Veri Seti

Analizler için uygun hava koşullarında çalışma alanının sırasıyla 15 Temmuz 2004 ve 11 Temmuz 2008 tarihli çok-bantlı IKONOS ve Kompsat-2 uydu görüntüleri kullanılmıştır (Şekil 1). Kullanılan her iki uydu görüntüsü mavi, yeşil ve kırmızı olmak üzere 3 adet görünür ve 1 adet yakın kızıl ötesi spektral bant içermektedir. Uydu görüntülerine ait mekânsal çözünürlük 4 metredir. IKONOS görüntüsüne ait spektral bant aralıkları sırasıyla mavi: 0.45–0.52 µm. yeşil: 0.51–0.60 µm. kırmızı: 0.63–0.70 µm ve yakın kızıl ötesi: 0.76–0.85 µm şeklindedir. Kompsat-2 görüntüsü de IKONOS görüntüsüne benzer özellikte dört spektral bant aralığını içermektedir(mavi: 0.45–0.52 µm. yeşil: 0.52–0.60 µm. kırmızı: 0.63–0.69 µm ve yakın kızıl ötesi: 0.76–0.90 µm.) Kompsat-2 görüntüsüne ait işlem seviyesi 2A'dır. Çalışmada kullanılan IKONOS uydu görüntüsünün işlem düzeyi ise standart formattadır. Bu işlem seviyelerinde görüntüler radyometrik olarak düzeltilip yer kontrol noktası (YKN) kullanılmaksızın geometrik düzeltme işlemi standart harita projeksiyonuna (UTM / WGS 84) göre yapılmaktadır. Görüntülere ait teknik detaylara Tablo 1' de yer verilmiştir.



Şekil 1. Çok-bantlı (a) IKONOS ve (b) Kompsat-2 uydu görüntüleri (Karacabey Ovasi)

| | | IKONOS | KOMPSAT-2 |
|------------------------|---------------------|---|---|
| Ürünler | | Çok-Bantlı | |
| Spektral Bantlar (µm) | | mavi: 0.45-0.52 yeşil: 0.51-0.60 kırmızı: 0.63-0.70 yakın kızıl ötesi: 0.76-0.85 | mavi: 0.45-0.52 yeşil: 0.52-0.60 kırmızı: 0.63-0.69 yakın kızıl ötesi: 0.76-0.90 |
| | Mekânsal Çözünürlük | 4m | 4m |
| Radyometrik Çözünürlük | 16 bit | | |
| Şerit Genişliği | 11 km | 15 km | |
| Görüntüleme Açısı | 26° | 30° | |
| İşlem Seviyesi | Standart | 2A | |
| Datum | WGS 84 | | |
| Harita Projeksiyonu | UTM | | |
| Zon Numarası | Zone 35 | | |

Tablo 1. IKONOS ve Kompsat-2 görüntülerine ait teknik detaylar

3. YÖNTEM

Çalışma yöntemi genel olarak 3 ana basamaktan oluşmaktadır. Bunlar; (i) ön işlem aşaması, (ii) görüntülere Çizge-tabanlı ve DVM yöntemlerinin uygulanması ve (iii) üretilen tematik haritaların doğruluk analizleridir. Çalışma yöntemine ilişkin bilgilere aşağıda detaylı şekilde yer verilmektedir.

3.1 Ön İşlemler

IKONOS uydu görüntüsü, Özdarıcı (2005) tarafından yapılan bir çalışmada 20 yer kontrol noktası kullanılarak geometrik olarak düzeltilmiştir. Geometrik düzeltme işlemi için ikinci derece polinom model ve düzeltme sonrasında hücrelere

atanacak yeni radyometrik değerler için en yakın uzaklık yöntemi kullanılmıştır. Yapılan geometrik düzeltme sonucunda ortaya çıkan karesel ortalama hata miktarı ± 0.41 piksel olarak hesaplanmıştır.

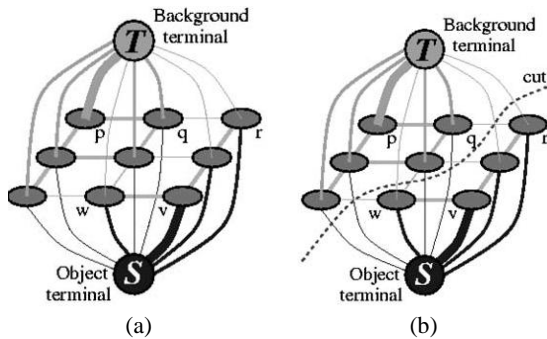
Kompsat-2 uydusu görüntüsü ise yine Özdarıcı Ok (2012) tarafından yapılan tez çalışmasında 19 yer kontrol noktası kullanılarak geometrik olarak düzeltilmiştir. IKONOS görüntüsü ile benzer şekilde Kompsat-2 uydusu görüntüsünün geometrik düzeltme işlemi de ikinci derece polinom model ve düzeltme sonrasında hücelere atanacak yeni radyometrik değerler için en yakın uzaklık yöntemi kullanılmıştır. Kompsat-2 görüntüsüne ait geometrik düzeltme işlemi sonrasında kaydedilen karesel ortalama hata miktarı ± 0.47 piksel olarak hesaplanmıştır.

Geometrik düzeltme işlemi sonrasında kontrollü sınıflandırmaları gerçekleştirebilmek için görüntüler üzerinde belirlenen her bir sınıf için örnek pikseller toplanmıştır.

3.2 Çizge-Tabanlı Yöntem

Belirli bir sayıda düğüm (V) ve komşu düğümleri birbirine bağlayan kenarlardan (E) oluşan ağ yapısı bir çizgeyi $G = \{V, E\}$ tanımlamaktadır (Şekil 2a). Çizgedeki düğümleri birbirine bağlayan kenarlar bir düğümden diğerine doğru bir şekilde (yönlü) veya herhangi bir yön belirtmeden (yönsüz) tanımlanabilmektedir. Görüntü işleme çalışmalarında bir çizgedeki düğümler genellikle görüntüyü oluşturan piksellere karşılık gelmekte ve iki komşu piksel (p, q) arası yönsüz bir ilişki tercih edilmektedir. Bir çizge piksellere karşılık gelen düğümlerden farklı olarak iki uç-düğüm, kaynak (S) ve hedef (T) düğümlerini içermektedir. Bu uç-düğümler piksellere atanacak ikili değerler (1 ve 0) gibi düşünülmekte ve örneğin ikili sınıflama işlemindeki piksellerin etiketini tanımlamaktadır (Şekil 2a). Şekil 2'den de görülebileceği üzere çizgedeki komşu pikseller birbirine kenarlarla bağlanarak bir ağ yapısı oluşturmaktadır. Düğümlerin birbirleriyle arasındaki kenarlar komşu-bağlı olarak tanımlanır ve düğümlerin birbirleriyle komşuluğunun bulunup bulunmadığı bilgisini içerir. Diğer taraftan bir uç düğümü diğer düğüme bağlayan kenarlara ise uç-kenar adı verilir. Bütün kenarlar negatif olmayan maliyet değerleri taşırlar ve herhangi iki düğüm (m, n) arasındaki maliyet değeri c_{mn} olarak tanımlanır (Boykov ve Funka-Lea, 2006).

Şekil 2a' da tanımlanan bir çizgede bulunan bütün düğümlerin her bir düğüme sadece bir uç-düğüm tarafından ulaşılabilecek şekilde kesilmesine çizge-kesme adı verilir. Böylece herhangi bir düğüme sadece bir uç-düğümünden (S veya T) ulaşılabilecektir.



Şekil 2 (a) 3x3 ağ yapısı şeklinde tanımlanmış bir çizge, (b) bu ağ yapısı üzerinde gerçekleştirilen bir çizge-kesme (Boykov ve Funka-Lea, 2006).

Dolayısıyla bu şekilde bir ayırım aynı zamanda her bir düğüm için ikili sınıflama işlemi gerçekleştirmektedir. Bu kesim işlemi doğal olarak çizge üzerinde çok farklı kısımlardan yapılabilecek ve farklı her bir çizge-kesme için çeşitli kenarlar ve/veya uç-kenarlar kullanılabilir. Bu nedenle aslında çizge-kesme problemi verilen maliyetler düşünülerek çizgeyi en uygun bir başka deyişle en az maliyetle ikiye ayıran kesme olacaktır. Herhangi bir çizge-kesmenin toplam maliyeti ise kesmeyi oluşturan kenarların maliyetlerinin toplanması ile hesaplanmaktadır ($\sum c_{mn}$). Bu nedenle aslında bir çizge için kesme problemi tüm olası kesmeler arasından en az toplam maliyet değeri karşılık gelen kesmeyi seçmek olarak tanımlanır. Bu problemin çözümünde ise minimum-kesme/maksimum-akış yöntemi (Kolmogorov ve Zabih, 2004; Boykov ve Kolmogorov, 2004) kullanılmaktadır.

Sınıflama problemleri bir enerji denklemini temel almakta ve sonuçta elde edilecek en uygun sınıflama, tanımlanan enerjiyi en aza indirgeyen sınıflama olarak elde edilmektedir. Bu denklem genelde iki farklı tipte enerjinin birleşimini içermekte ve aşağıdaki gibi tanımlanmaktadır (Boykov ve Funka-Lea, 2006):

$$\hat{c} = \operatorname{argmin}[\sum_{n=1}^N U_n(c_n) + \sum_{(m,n) \in C} P_{mn}(c_m, c_n)] \quad (1)$$

Yukarıdaki eşitlikte $U_n(c_n)$ veri enerjisini, $P_{mn}(c_m, c_n)$ düzeltme enerjisini, N toplam piksel (düğüm) sayısını, C ise komşuluğu tanımlamaktadır. Eşitlik (1)'de tanımlanan veri enerjisi bir piksele herhangi bir sınıfın atanmasının maliyetini belirtmektedir. Yani bir başka deyişle, eğer bir pikselin bir sınıfa ait olma olasılığı yüksek ise onun veri maliyeti düşük olacaktır. Bu şekilde tüm pikseller ele alındığında veri enerjisi tüm piksellere en az maliyetle atanabilecek sınıf etiketlerini içermektedir. Eşitlik (1)'de tanımlanan düzeltme enerjisi ise komşu pikseller arası benzerlikleri dikkate alarak o piksellere benzer sınıf etiketleri atanmasının maliyetini hesaplar. Örneğin birbirinden farklı spektral yansıma değerlerine sahip iki komşu piksel arası maliyet fazla olacak ve bu nedenle sınıf etiketleri farklı tanımlanabilecektir. Tam tersi şekilde birbirine yakın spektral değerlere sahip komşu pikseller arası düzeltme maliyeti az olacak ve aynı sınıf etiketleri atanabilecektir. Bu şekilde bir çizgede kesme işleminin birbirlerine en az benzeyen kenarlar üzerinden yapılması tüm görüntü üzerinde bir düzeltme etkisi sağlamış olacaktır. Eşitlik (1)'de verilen toplam enerji fonksiyonunun bir çizge üzerinde minimize edilmesi (en az maliyetli olan çizge-kesmenin bulunması) hem veri enerjisi hem de düzeltme enerjisi bakımından görüntüyü ele aldığı için bu yöntemlere global sınıflandırma yöntemleri adı da verilmektedir (Boykov ve Funka-Lea, 2006).

Uzaktan algılama çalışmalarında veri enerjisi görüntü üzerinde toplanan örnek alanlar kullanılarak hesaplanabilir. Bu çalışmada her bir sınıfa ait veri maliyetlerinin hesaplanması için Gauss Karışım Modelleri (GKM) kullanılmıştır. GKM verinin bir veya daha çok Gauss dağılımının ağırlıklı bileşimi olarak gösterilmesine dayanan istatistiksel bir yöntemdir (McLachlan ve Peel, 2000):

$$p(\mathbf{x}|\theta) = \sum_{i=1}^M \omega_i g(\mathbf{x}|\mu_i, \Sigma_i) \quad (2)$$

Yukarıdaki eşitlikte M seçilen Gauss Modeli sayısını, ω_i karışımın ağırlıklarını $\sum_{i=1}^M \omega_i = 1$, $g(\cdot)$ fonksiyonu Gauss dağılımını μ_i ve Σ_i ise Gauss dağılımına ait ortalama ve kovaryans bilgilerini içermektedir. Dolayısıyla her bir sınıfa ait

hesaplanacak olan GKM parametreleri (θ) aşağıdaki şekilde özetlenebilir:

$$\theta = (\omega_i, \mu_i, \Sigma_i) \quad (3)$$

Uydu görüntülerinin çok-bantlı (K) olması dolayısıyla \mathbf{x} , K -boyutlu bir bilgi içermektedir ve modelin parametreleri verilen GKM sayısına göre Beklenti Maksimizasyon (EM) yöntemi ile çözülmektedir. Bu çalışmada sınıfların ait olabileceği alt-sınıf sayıları göz önüne alınarak M değeri 5 olarak alınmıştır. Bir sınıfa ait GKM elde edildikten sonra ilgili sınıfa ait veri enerjisi ise negatif logaritmik olasılık değeri, $-\log(p(\mathbf{x}|\theta))$, alınarak hesaplanabilmektedir.

Bu çalışmada düzeltme enerjisi için Rother vd., (2004) çalışmasında önerilen yaklaşım kullanılmıştır:

$$P_{mn}(c_m, c_n) = \gamma \sum_{m,n \in C} \frac{e^{-\beta \|z_m - z_n\|}}{dis(m,n)} \quad (4)$$

Yukarıdaki eşitlikte γ düzeltme katsayısını, $dis(m,n)$ fonksiyonu m ve n piksellerinin görüntüde birbirlerine olan uzaklığını, z_m ve z_n piksellerin spektral değerlerini, $\| \cdot \|$ Öklid mesafesini ve β ise her görüntü için $\beta = (2\|z_m - z_n\|^2)^{-1}$ şeklinde hesaplanan bir katsayıyı belirtmektedir. Bu çalışmada düzeltme katsayısı olarak IKONOS ve Kompsat-2 görüntüleri için en iyi sonucu verdiğini hesapladığımız 20 değeri seçilmiştir.

Eşitlik (1)'de tanımlanan enerji denklemi ikili sınıflama durumunda maksimum-akış yöntemi kullanılarak çözülebilmektedir. Fakat ikiden fazla sınıf bulunması durumunda enerji fonksiyonunun optimizasyonu için yaklaşık yöntemler kullanılmaktadır. Bu yöntemlerden bir tanesi α -açılım yöntemidir (Boykov vd., 2001). Bu yöntem genel olarak çok sınıflı problemi yinelemeli bir şekilde ele almakta ve sonucu kesin olarak çözülebilen ikili problemlere dönüştürmektedir. Kısaca yöntem her yineleme sırasında bir sınıf etiketi seçmekte ve her piksel için o etiketin hâlihazırda tanımlanmış etiketten daha uygun olup olmadığını kontrol etmektedir. Bu sayede eşitlik (1)'de tanımlanan enerji denkleminin toplam maliyet değerini küçültmeye çalışmaktadır. Yapılan çalışmalara göre bu yöntem enerji denklemlerinin global minimumunu elde edemese bile global minimuma belirli yakınlıkta ($2x$) sonuçlar üretmektedir.

3.3 Destek Vektör Makineleri

DVM yönteminin uzaktan algılama çalışmalarında başarılı sonuçlar üretmesi bu yöntemin güvenilirliğini arttırmış ve yöntem, geleneksel görüntü sınıflandırma algoritmaları arasındaki yerini almıştır. DVM yöntemi, tanımlanan örnek piksellere bağlı olarak sınıflar arasındaki sınırları en uygun düzeyde tutmaya yarayan hiper-düzlem denilen karar sınırlarının tanımlanması ve bu sayede pikseller arasındaki yanlış sınıflandırma olasılığının en aza indirilmesi mantığına dayanır (Vapnik, 1995; Vapnik, 1998). Yöntem ilk olarak iki sınıfı birbirinden ayırmak amacıyla $\{-1,+1\}$ şeklinde etiketleme yapılabilen doğrusal sınıflandırma problemlerini çözmek için tasarlanmıştır. Doğrusal problemlerde hiper-düzlemler iki sınıfı birbirinden etkin şekilde ayırabilmek için 'mesafe (margin)' denilen en yüksek açıklık seviyesine sahip olmalıdır. Daha açık bir ifadeyle DVM yöntemi, hiper-düzlem ve örnek pikseller arasındaki uzaklığı en yüksek düzeyde tutacak optimum hiper-düzlemi tanımlamaya dayanır. Optimum hiper-düzlemler

üzerinde kalan pikseller destek vektörlerini oluşturur ve bu destek vektörleri görüntüdeki bilinmeyen piksellerin sınıflandırılmasında kullanılır (Tso and Mather, 2009).

Doğrusal düzlemler dünya yüzeyindeki problemlerin çözümü için çoğu zaman yeterli olamamaktadır. Bu nedenle doğrusal olmayan hiper-düzlem kavramı geliştirilmiştir. Bu kavrama göre sınıflar arasındaki ayırımı en iyi şekilde yapabilmek için veri, çok boyutlu Hilbert uzayı da denilen Öklid uzayına taşınır. Bu işlem için kullanıcı tarafından tanımlanan C (penaltı) parametresi gereklidir. DVM performansını çok boyutlu uzayda etkin hale getirebilmek için çeşitli kernel tipleri tanımlanmıştır (örn. doğrusal, polinom, radyal tabanlı fonksiyon veya sigmoid) (Vapnik, 1995). Literatürde radyal tabanlı fonksiyon kernelinin genellikle analizlerde en güvenilir sonucu verdiği gözlenmiş bu nedenle bu çalışmada radyal kernel tipi kullanılmıştır (Eşitlik 5).

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (5)$$

Eşitlikteki γ terimi kernel fonksiyonun boyutunu tanımlamaktadır.

Kullanılan test veri seti için DVM yönteminin en yüksek performansı hangi parametre bileşenlerince (γ ve C) sağladığını bulabilmek için görüntüler üzerinde çeşitli parametre kombinasyonları denenmiştir. Yapılan deneyler sonucunda IKONOS görüntüsü için $\gamma = 25$ ve $C = 2000$ parametrelerinin, Kompsat-2 görüntüsü için ise $\gamma = 25$ ve $C = 200$ parametre bileşenlerinin en yüksek sınıflama doğruluklarını sağladığı gözlenmiş ve görüntülerin DVM sınıflandırmaları bu parametreler kullanılarak gerçekleştirilmiştir.

3.4 Doğruluk Analizi

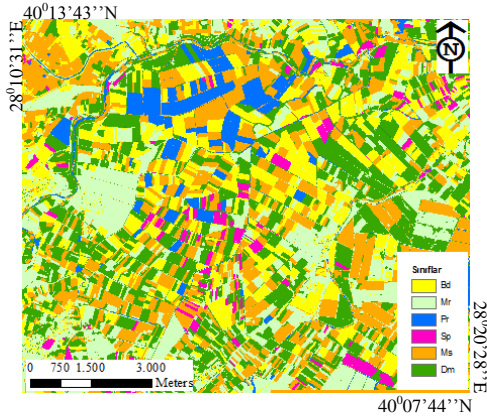
Çizge tabanlı ve DVM yöntemlerinin görüntülere uygulanması sonucunda elde edilen tematik haritaların değerlendirilebilmesi için piksel tabanlı hata matrisleri üretilmiştir. Bu sayede her bir görüntüdeki 6 ürün sınıfına ait piksel tabanlı üreticive kullanıcı doğrulukları ile genel hata oranları ve kappa değerleri hesaplanarak sınıflandırma yöntemlerinin tarımsal ürün haritalamadaki başarısı incelenmiştir. Doğruluk analizlerinde arazi çalışmaları sırasında toplanmış ve alanın yaklaşık %30'unu kapsayan referans veriler kullanılmıştır. Analizlerde en güvenilir doğruluk sonuçlarına ulaşabilmek amacıyla referans veriye karşılık gelen tüm pikseller doğruluk hesaplamalarında değerlendirilmiştir. Analizler sonucunda elde edilen hata matrisleri Bölüm 4'te detaylı olarak incelenmektedir.

4. TARTIŞMA

Tablo 2'de 2004 tarihli IKONOS uydu görüntüsünün Çizge-tabanlı yöntem yoluyla sınıflandırılması sonucunda üretilmiş hata matrisi verilmektedir. Sınıflandırmaya dâhil edilen ürün sınıfları matriste şu kısaltmalarla tanımlanmaktadır: Buğday-*Bd*, Pirinç-*Pr*, Şeker pancarı-*Şp*, Mısır-*Mr*, Domates-*Dm*. Tablo 2'ye göre IKONOS görüntüsünün Çizge-tabanlı yöntem yoluyla sınıflandırılması sonucunda üretilen tematik harita, bu haritaya karşılık gelen toplam 1,840,093 referans piksel ile karşılaştırılmış ve bu karşılaştırma sonucunda %82.36 genel doğruluk ve 0.77 kappa değeri elde edilmiştir. Sınıflara ait kullanıcı doğrulukları, *Bd* dışındaki ürün türleri için %85'in üzerinde hesaplanmıştır. En yüksek kullanıcı doğruluğu %97.82 ile *Ms* ürünü için hesaplanmıştır. Diğer taraftan matriste ait en düşük kullanıcı doğruluğu %65.71 ile *Bd* için kaydedilmiştir.

Buna karşılık matrisin üretici doğruluklarının bulunduğu değerler en yüksek üretici doğruluğunun %98.29 ile *Bd* bitkisi için hesaplandığını göstermiştir. *Pr*, *Ms* ve *Dm* ürünleri de Çizge-tabanlı yöntem sonucunda %90'nın üzerinde üretici doğruluğu sağlamıştır. Diğer taraftan en düşük üretici doğruluğu ürünler içinde en yüksek kullanıcı doğruluğuna sahip *Mr* sınıfı (%97.82) için %41.58 olarak bulunmuştur. *Şp* sınıfına ait üretici doğruluğu ise %66.56'dır. Sonuçlar genel olarak ele alındığında, *Bd* sınıfına ait kullanıcı doğruluğu (%65.71) ve *Mr* ve *Şp* sınıfları için hesaplanan üretici doğrulukları (%41.58 ve %66.56) dışında Çizge-tabanlı yöntem IKONOS görüntüsü için yüksek sonuçlar üretmiştir. Çizge-tabanlı yöntem sonucunda üretilen tematik harita ve sınıf gösterimleri Şekil 3'de verilmektedir.

Tablo 3 IKONOS görüntüsünün DVM yöntemi ile sınıflandırılması yoluyla üretilen hata matrisi değerlerini göstermektedir. DVM yöntemi sonucunda elde edilen tematik haritanın referans piksellerle karşılaştırılması sonucunda %77.50 genel hata ve 0.71 kappa değeri hesaplanmıştır. Diğer bir deyişle DVM yöntemi aynı alanın Çizge-tabanlı yöntem sonucunda hesaplanan genel hata değerinden yaklaşık %5 daha düşüktür. Ürünler için kullanıcı doğrulukları tüm ürünler için %70'in üzerinde hesaplanmıştır. En yüksek kullanıcı doğruluğu *Mr* ve *Şp* sınıfları için yaklaşık %90 olsa da bu sınıflara ait üretici doğruluğu oldukça düşüktür (*Mr*:%48.52 ve *Şp*: %42.75). Bunun nedeni, *Mr* sınıfına ait piksellerin çoğunlukla *Bd* ve *Ms* sınıflarıyla, *Şp* sınıfının ise çoğunlukla *Dm* ile karışmasıdır.



Şekil 3. IKONOS görüntüsünün Çizge Tabanlı Yöntem ile sınıflandırılması sonucunda üretilmiş tematik harita

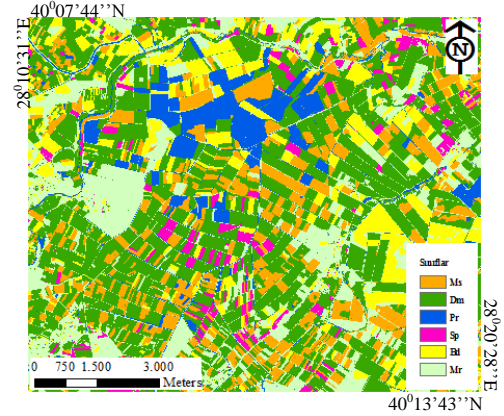
| | <i>Bd</i> | <i>Mr</i> | <i>Pr</i> | <i>Şp</i> | <i>Ms</i> | <i>Dm</i> | ST |
|--------------------------|---------------|--------------------|---------------|--------------|---------------|---------------|---------|
| <i>Bd</i> | 374703 | 2785 | 6 | 55 | 3204 | 454 | 381207 |
| <i>Mr</i> | 175635 | 154356 | 430 | 1274 | 19236 | 20285 | 371216 |
| <i>Pr</i> | 111 | 19 | 142142 | 29 | 6782 | 165 | 149248 |
| <i>Şp</i> | 59 | 1 | 3181 | 60832 | 171 | 27138 | 91382 |
| <i>Ms</i> | 14419 | 306 | 3376 | 372 | 408957 | 9062 | 436492 |
| <i>Dm</i> | 5289 | 320 | 2103 | 1777 | 26497 | 374562 | 410548 |
| KT | 570216 | 157787 | 151238 | 64339 | 464847 | 431666 | 1840093 |
| KD | 65.71 | 97.82 | 93.98 | 94.54 | 87.97 | 86.77 | |
| ÜD | 98.29 | 41.58 | 95.23 | 66.56 | 93.69 | 91.23 | |
| Genel Hata: 82.36 | | Kappa: 0.77 | | | | | |

Tablo 2. IKONOS görüntüsünün Çizge tabanlı yöntem yoluyla sınıflandırılması sonucunda üretilen tematik haritaya ait hata matrisi (ST: Sıra toplamı, KT: Kolon toplamı, KD: Kullanıcı doğruluğu, ÜD: Üretici doğruluğu)

| | <i>Bd</i> | <i>Mr</i> | <i>Pr</i> | <i>Şp</i> | <i>Ms</i> | <i>Dm</i> | ST |
|--------------------------|---------------|--------------------|---------------|--------------|---------------|---------------|---------|
| <i>Bd</i> | 429197 | 7513 | 33 | 43 | 6373 | 894 | 444053 |
| <i>Mr</i> | 110432 | 142416 | 280 | 892 | 14985 | 24491 | 293496 |
| <i>Pr</i> | 198 | 51 | 131753 | 680 | 17304 | 5697 | 155683 |
| <i>Şp</i> | 413 | 34 | 4685 | 58768 | 364 | 73204 | 137468 |
| <i>Ms</i> | 13957 | 316 | 10559 | 296 | 359699 | 22964 | 407791 |
| <i>Dm</i> | 16019 | 7457 | 3928 | 3660 | 66122 | 304416 | 401602 |
| KT | 570216 | 157787 | 151238 | 64339 | 464847 | 431666 | 1840093 |
| KD | 75.26 | 90.25 | 87.11 | 91.34 | 77.38 | 70.52 | |
| ÜD | 96.65 | 48.52 | 84.62 | 42.75 | 88.20 | 75.80 | |
| Genel Hata: 77.50 | | Kappa: 0.71 | | | | | |

Tablo 3. IKONOS görüntüsünün DVM yöntemiyle sınıflandırılması sonucunda üretilen tematik haritaya ait hata matrisi (ST: Sıra toplamı, KT: Kolon toplamı, KD: Kullanıcı doğruluğu, ÜD: Üretici doğruluğu)

Şekil 4'de 2008 tarihli Kompsat-2 uydu görüntüsünün Çizge-tabanlı yöntem sonucu ve Tablo 4' de bu yöntem sonucunda üretilmiş hata matrisi verilmektedir. Buna göre Çizge-tabanlı yöntem, Kompsat-2 görüntüsü için %89.32 genel doğruluk ve 0.85 kappa değeri üretilmiştir. Kullanıcı doğrulukları tüm ürün türleri için %80'in üzerinde hesaplanmıştır. En yüksek kullanıcı doğruluğu yaklaşık %96 ile *Mr* ve *Pr* sınıfları için elde edilmiştir. Sınıflara ait üretici doğrulukları, *Bd*, *Pr* ve *Şp* bitkilerinin %90'ın üzerinde sonuçlar ürettiğini göstermiştir. En yüksek üretici doğruluğu %99.60 ile *Şp* için gözlenmiştir. *Dm* ürününe ait kullanıcı doğruluğu %86.88 olmasına karşın bu ürün türü için hesaplanan üretici doğruluğu (%31.67) oldukça düşüktür. Bunun nedeni, referans veride sayısı 31,026 olan piksellerin sadece 9,828'inin *Dm* olarak sınıflandırılmasıdır. *Dm* ürün türü için en çok karışım 10,148 piksel ile *Şp* ve 5,216 piksel ile *Pr* ürünleri için gözlenmiştir.



Şekil 4. Kompsat-2 görüntüsünün Çizge Tabanlı Yöntem ile sınıflandırılması sonucunda üretilmiş tematik harita

| | <i>Bd</i> | <i>Mr</i> | <i>Pr</i> | <i>Şp</i> | <i>Ms</i> | <i>Dm</i> | ST |
|--------------------------|---------------|--------------------|---------------|--------------|--------------|--------------|--------|
| <i>Bd</i> | 279396 | 6292 | 291 | 24 | 0 | 0 | 286003 |
| <i>Mr</i> | 2765 | 210872 | 2068 | 3002 | 883 | 1233 | 273717 |
| <i>Pr</i> | 269 | 97 | 229997 | 2656 | 141 | 37 | 233197 |
| <i>Şp</i> | 30 | 20 | 51 | 78637 | 130 | 81 | 78949 |
| <i>Ms</i> | 55659 | 229 | 997 | 368 | 16936 | 132 | 21427 |
| <i>Dm</i> | 2305 | 799 | 5216 | 10148 | 2730 | 9828 | 31026 |
| KT | 340424 | 218309 | 238620 | 94835 | 20820 | 11311 | 924319 |
| KD | 82.07 | 96.59 | 96.38 | 82.91 | 81.34 | 86.88 | |
| ÜD | 97.68 | 77.04 | 98.62 | 99.60 | 79.04 | 31.67 | |
| Genel Hata: 89.32 | | Kappa: 0.85 | | | | | |

Tablo 4. Kompsat-2 görüntüsünün Çizge tabanlı yöntemle sınıflandırılması sonucunda üretilen tematik haritaya ait hata matrisi (ST: Sıra toplamı, KT: Kolon toplamı, KD: Kullanıcı doğruluğu, ÜD: Üretici doğruluğu)

Kompsat-2 görüntüsünün (2008) DVM yöntemi ile sınıflandırılması sonucunda %82.72 genel hata ve 0.77 kappa değeri elde edilmiştir (Tablo 5). Bu oran kabul edilebilir olmasına karşın görüntünün Çizge-tabanlı yöntem sonucunda elde edilen tematik harita doğruluğundan yaklaşık %7 daha düşüktür. Sınıflara ait kullanıcı doğrulukları incelendiğinde tüm ürün tiplerine ait doğrulukların %80'in üzerinde olduğu söylenebilir. En yüksek üretici doğruluğu %96.61 ile *Pr* ürünü için hesaplanmıştır. Bu doğruluğu %95.28 ile *Şp* ürünü takip etmektedir. *Bd*'ya ait üretici doğruluğu da (%92.59) oldukça yüksektir. *Mr* sınıfı kabul edilebilir bir üretici doğruluğu (%77.53) sağlamasına rağmen DVM yöntemi sonucunda *Ms* (%47.20) ve *Dm* (%14.26) sınıfları için oldukça düşük sonuçlar ortaya çıktığı gözlenmiştir. Toplam 65,952 olan referans verinin yalnız 9,405 pikseli *Dm* olarak sınıflandırılmıştır. *Dm* sınıfı ile en çok karışma sırasıyla 18,825, 18,344 ve 11,613 piksel ile *Mr*, *Pr* ve *Şp* sınıfları arasında olmuştur. *Ms* sınıfında ise en çok karışma *Bd* ve *Pr* sınıfları arasındadır.

| | <i>Bd</i> | <i>Mr</i> | <i>Pr</i> | <i>Şp</i> | <i>Ms</i> | <i>Dm</i> | ST |
|-----------|---------------|--------------------------|---------------|--------------------|--------------|--------------|--------|
| <i>Bd</i> | 278920 | 21361 | 763 | 48 | 90 | 34 | 301216 |
| <i>Mr</i> | 47868 | 176000 | 672 | 1384 | 485 | 584 | 226993 |
| <i>Pr</i> | 339 | 198 | 207806 | 5934 | 528 | 273 | 215078 |
| <i>Şp</i> | 963 | 917 | 860 | 75682 | 127 | 879 | 79428 |
| <i>Ms</i> | 7328 | 1008 | 10175 | 174 | 16831 | 136 | 35652 |
| <i>Dm</i> | 5006 | 18825 | 18344 | 11613 | 2759 | 9405 | 65952 |
| KT | 340424 | 218309 | 238620 | 94835 | 20820 | 11311 | 924319 |
| KD | 81.93 | 80.61 | 87.08 | 79.80 | 80.84 | 83.14 | |
| ÜD | 92.59 | 77.53 | 96.61 | 95.28 | 47.20 | 14.26 | |
| | | Genel Hata: 82.72 | | Kappa: 0.77 | | | |

Tablo 5. Kompsat-2 görüntüsünün DVM yöntemiyle sınıflandırılması sonucunda üretilen tematik haritaya ait hata matrisi (ST: Sıra toplamı, KT: Kolon toplamı, KD: Kullanıcı doğruluğu, ÜD: Üretici doğruluğu)

5. SONUÇLAR

Bu çalışmada tarım alanlarının sınıflandırılması için Çizge-tabanlı yeni bir sınıflandırma önerilmiştir. Sonuçlar, Çizge-tabanlı yöntem performansının aynı alan için farklı tarihlerde çekilmiş çok-bantlı IKONOS ve Kompsat-2 uydu görüntülerinin DVM yöntemiyle elde edilen tematik harita doğruluklarından yüksek sonuçlar ürettiğini ortaya koymuştur. Karacabey Ovası'nın 2004 tarihli IKONOS görüntüsü için uygulanan Çizge-tabanlı yöntem, DVM yöntemi sonucunu yaklaşık %5 oranında arttırarak %82.36 genel doğruluk üretmiştir. Aynı alanın 2008 tarihli Kompsat-2 görüntüsünün Çizge-tabanlı yöntem sonucu DVM yöntemi ile elde edilen tematik harita doğruluğunu yaklaşık %7 oranında iyileştirerek %89.32 genel doğruluk sağlamıştır. Benzer düzeylerdeki iyileşmeler sınıflandırmaların kappa değerleri için de gözlenmiştir. Bu nedenle, elde edilen sınıflandırma sonuçları, önerilen Çizge-tabanlı yöntemin her iki görüntü için de geleneksel DVM yönteminden üstün sonuçlar ürettiğini göstermekte ve bu yöntemin tarımsal ürün haritalamada kullanımının güvenilir sonuçlar üretebileceğine işaret etmektedir.

REFERANSLAR

Boykov, Y., Funka-Lea, G., 2006. Graph cuts and efficient N-D image segmentation. *International Journal of Computer Vision*, 70(2), pp. 109–131.

Boykov, Y., Kolmogorov, V., 2004. An experimental comparison of min-cut/max-flow algorithms for energy

minimization in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(9), 1124-1137.

Boykov, Y., Veksler, O., Zabih, R., 2001. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11), 1222-1239.

Breiman, L., 2001. *Random Forests, Machine learning*. Kluwer Academic Publishers, the Netherlands.

Horning, N., 2010. Random forests: an algorithm for image classification and generation of continuous fields data sets. *International Conference on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences*, 9-11 December, Hanoi, Vietnam.

Jay, S., Lawrence, R., Repasky, K., Keith, C., 2009. Invasive species mapping using low cost hyperspectral imagery. *ASPRS Annual Conference*, Baltimore, Maryland.

Kolmogorov, V., Zabih, R., 2004. What energy functions can be minimized via graph cuts? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(2), 147-159.

Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2005. *Remote Sensing and Image Interpretation*. Wiley, USA, pp. 552-572.

McLachlan, G., Peel, D., 2000. *Finite Mixture Models*. Hoboken, NJ: John Wiley & Sons, Inc.

Özdarıcı Ok, A., 2011. *A Segment-Based Approach to Classify Agricultural Lands using Multi-Temporal Kompsat-2 and Envisat ASAR Data*, Doktora Tezi, Orta Doğu Teknik Üniversitesi, Türkiye.

Özdarıcı, A., 2005. *Comparison of Different Spatial Resolution Images for Polygon-Based Crop Mapping*, Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, Türkiye.

Prasad, A.M., Iverson, L.R., Liaw, A., 2006. Newer classification and regression tree techniques: bagging and random forests for ecological prediction. *Ecosystems*, 9(2), 181-199.

Rother, C., Kolmogorov, V., Blake, A., 2004. Grabcut: interactive foreground extraction using iterated graph cuts. *ACM Transactions on Graphics*, 23(3), pp. 309-314.

Tso, B., and Mather, P.M., 1999. Crop discrimination using multi-temporal SAR imagery. *International Journal of Remote Sensing*, 20(12), 2443-2460.

Turker, M., Ozdarici, A., 2011. Field-based crop classification using SPOT4, SPOT5, IKONOS, and QuickBird imagery for agricultural areas: a comparison study. *International Journal of Remote Sensing*, 32: 9735-9768.

Vapnik, V., 1995. *The Nature of Statistical Learning Theory*. New York, Springer-Verlag.

Vapnik, V., 1998. *Statistical Learning Theory*. New York, Springer-John Wiley.

Waske, B., Braun, M., 2009. Classifier ensembles for land cover mapping using multitemporal SAR imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 450-457.