

YENİ NESİL ÇİZGE-TABANLI GÖRÜNTÜ SINIFLANDIRMA YÖNTEMİNİN TARIMSAL ÜRÜN DESENİ ÜZERİNDEKİ ETKİSİNİN İNCELENMESİ

A. Özdarıcı Ok^a, A. Ö. Ok^a, K. Schindler^b

^a Nevşehir H.B.V. Üniversitesi, Jeodezi ve Fotogrametri Mühendisliği, 50300 Nevşehir, Türkiye - (asliok, ozgunok)@nevsehir.edu.tr
^b ETH, Photogrammetry and Remote Sensing, 8093 Zurich, Switzerland - schindler@geod.baug.ethz.ch

ANAHTAR KELİMELE: Tarım, Görüntü Sınıflandırma, Çizge-tabanlı Yöntem, Rastgele Orman, Destek Vektör Makineleri

ÖZET:

Bu çalışmada yeni nesil görüntü sınıflandırma yöntemlerinden biri olan çizge-tabanlı yaklaşımın tarımsal ürün deseni üzerindeki etkisi incelenmektedir. Çizge-tabanlı yaklaşım, görüntüde piksellere ait komşuluk ilişkilerini de dikkate alarak sınıflandırmayı tüm görüntü üzerinde global olarak gerçekleştiren bir yöntemdir. Yöntemin performansını test etmek amacıyla farklı tarihlerde (2004 ve 2008) Bursa'daki Karacabey Ovası'ndan çekilen çok bantlı QuickBird-2 (2.4m), Ikonos (4m) ve iki farklı Kompsat-2 (4m, Haziran ve Temmuz) uydu görüntüleri kullanılmıştır. Görüntülerin kapladığı alan yaklaşık 100km² olup bölgede başlıca mısır, pirinç, şeker pancarı, buğday ve domates tarımı yapılmaktadır. Bölge ayrıca mera alanları da içermektedir. Çalışmada kullanılan görüntüler altı ürün sınıfı için ilk olarak ham Rastgele Orman (RO) ve Destek Vektör Makineleri (DVM) yöntemleri ile sınıflandırılmıştır. Ardından görüntüler çizge-tabanlı yöntemle ait iki farklı düzleştirme filtre fonksiyonu (lineer karışıklık ve üstel) kullanılarak RO ve DVM yöntemleri ile tekrar sınıflandırılmıştır. En güvenilir sınıflandırma sonuçları, parametre hassasiyet testleri yardımıyla bulunan optimum parametre kombinasyonu yoluyla elde edilmiş ve sonuçlar hata matrisleri yardımıyla hesaplanmıştır. Elde edilen bulgular, görüntüye ait en yüksek doğruluk oranlarının DVM yöntemi ile bütünleşik çizge tabanlı yöntemin üstel düzleştirme filtresi kullanımı sonucunda elde edildiğini göstermiştir. En yüksek genel doğruluk oranları QuickBird-2 görüntüsünün sınıflandırılması yoluyla üretilen tematik harita için %90.8, Ikonos görüntüsü için %86.4 ve Kompsat-2 görüntüleri için sırasıyla 74.4% (Haziran), 93.3% (Temmuz) olarak hesaplanmıştır. Sonuçlar, çizge tabanlı yöntemin ham sınıflandırma yöntemlerine ait sonuçlardan yaklaşık %10 oranında daha güvenilir olduğunu göstermiştir. Elde edilen Kappa verileri de bu sonuçları desteklemektedir. Sonuçların güvenilir haritalar üretilmesinde tarımla ilgilenen kurum ve kuruluşlara, karar vericilere ve bilim insanlarına yön vereceği düşünülmektedir.

KEY WORDS: Agriculture, Image Classification, Graph-based method, Random forest, Support vector machine

ABSTRACT:

In this study, we investigate the performance of a graph-based, global image classification method, for agricultural crop mapping. The approach performs the classification globally over an image, taking into account the neighborhood relationships between pixels. During the analysis, four multispectral images (QuickBird-2 (2.4m), Ikonos (4m) and two Kompsat-2 images (4m)) of Karacabey Plain (Bursa, Turkey) acquired at two different times (2004 and 2008) are utilized. The test site covers approximately 100 km² and the major crop types cultivated in the test site are corn, rice, sugar beet, wheat, and tomato. The study area also contains several patches of grassland. Images are first classified independently per pixel with either a Random Forest (RF) or a Support Vector Machine (SVM). Thereafter, the images are classified with the graph-based strategy, using the two different unary potentials from RF and SVM, and two different smoothing functions (linear contrast and exponential). Each combination is evaluated quantitatively with optimal parameter settings (determined through extensive tests). The best results are achieved with the graph-based strategy, with SVM unaries and exponential smoothing. The best overall accuracies are 90.8% for QuickBird-2, 86.4% for Ikonos, 74.4% for Kompsat-2 recorded in June, and 93.3% for Kompsat-2 recorded in July. Thematic maps produced with the graph-based strategy are about 10% more correct than those from the raw classifier output. Kappa statistics are also evaluated, and closely correlate with the overall accuracies. The study suggests that the proposed method could be helpful to generate reliable maps for agricultural communities, decision makers, and scientists interested in agricultural studies.

1. GİRİŞ

Uzaktan algılama teknolojisi ile tarım alanlarının görüntülenmesi, geçmiş yıllara ait ürün bilgisinin yanı sıra gelecek yıllar için ürün tahmini yapılmasına olanak sağlamakta ve bu sayede ekonomiye yön vermek adına karar vericilere ışık tutmaktadır. Ürün tahmini, özellikle ekonomisinin büyük kısmı tarıma dayalı ülkeler için önemlidir. Ürün tahmininin geleneksel yöntemler yerine uzaktan algılama teknolojileri kullanılarak gerçekleştirilmesi, daha düşük maliyetlerle büyük alanlar üzerinde tekrar edilebilir güvenilir çalışmalara olanak sağlayarak insan gücünden ve zamandan tasarruf etmek açısından büyük kolaylıklar sağlamaktadır. Bu amaçla kullanılan en popüler yöntem otomatik görüntü sınıflandırmasıdır. Diğer taraftan uydu teknolojilerinin

gelişmesine paralel olarak artan çözünürlük kabiliyeti detayla birlikte bir takım zorlukları da beraberinde getirmiştir. Bu durum araştırmacıları istatistiksel yöntemlerin yanında makine öğrenme yöntemleri olarak adlandırılan ve verinin herhangi bir dağılıma sahip olmadığını varsayan farklı sınıflandırma yöntemleri geliştirmeye yöneltmiştir. Bu yöntemlerin en popüler olanları arasında Destek Vektör Makineleri (DVM) ve Rastgele Orman (RO) sınıflandırma teknikleri gelmektedir. Söz edilen yöntemler, güvenilir sonuçlar üretmekle birlikte sadece spektral değerleri kullanıp mekânsal bilgiyi göz ardı etmektedir. Bu nedenle günümüzde mekânsal bilgiyi de dikkate alan yeni nesil yöntemlere ihtiyaç duyulmaktadır.

Bu çalışmada bilgisayarda görü çalışmalarında yakından tanınan fakat uzaktan algılama çalışmalarındaki varlığı henüz yeni olan

çizge tabanlı görüntü sınıflandırma yaklaşımının tarımsal ürün deseni tespiti üzerindeki etkisi incelenmektedir. Önerilen yöntem, kontrollü bir sınıflandırma tekniği olup sınıflandırma sırasında pikseller arası mekânsal komşuluk etkileşimlerini dikkate almakta ve bu etkileşimlerden yararlanarak sınıflandırma doğruluğunu arttırmayı hedeflemektedir. Sınıflandırma işleminde çizgedeki her bir düğüme karşılık gelen maliyet değerlerinin hesaplanması için toplanan örnek alanlara ait piksellerin spektral yansıma değerleri dikkate alınmaktadır. Ardından, komşu pikseller arasındaki spektral ve/veya mekânsal mesafeyi dikkate alan fonksiyonlar yardımıyla birbirleriyle komşu olan pikseller arasında oluşturulan kenarlara ağırlıklar atanmaktadır. Çizge-tabanlı yöntem ile birlikte uygulanan DVM ve RO teknikleri, Bursa'da bulunan Karacabey Ovası'ndaki bir tarım alanı üzerinde 2 farklı tarihte (2004 ve 2008) yetiştirilen 6 farklı ürün tipi için test edilmiş ve sonuçlar hata matrisleri yoluyla değerlendirilmiştir.

Önerilen çalışma planı şöyle tanımlanmaktadır: Bölüm 2'de çalışma alanı ve kullanılan veri seti tanımlanmaktadır. Önerilen çizge-tabanlı yöntemin detayları Bölüm 3'te açıklanmakta ve 4. bölümde sınıflandırmalar sonucunda elde edilen bulgular tartışılmaktadır. Bölüm 5'te çalışmadan elde edilen sonuçlar değerlendirilmektedir.

2. ÇALIŞMA ALANI VE VERİ SETİ

Çalışma, Bursa'nın Karacabey ilçesindeki Karacabey Ovası'nın 100 km² lik bölümünde gerçekleştirilmiştir. Alanda yetiştirilen başlıca tarım ürünleri, mısır, domates, buğday, pirinç ve şeker pancarıdır. Bunun yanında alanda çiftlik hayvanları için mera alanları da bulunmaktadır. Analizler çalışma alanının iki farklı yıla ait çok bantlı QuickBird-2 (2.4m, Ağustos, 2004), Ikonos (4m, Temmuz, 2004) ve iki farklı Kompsat-2 (4m, Haziran ve Temmuz, 2008) uydu görüntüleri üzerinde gerçekleştirilmiştir. Kullanılan görüntüler, mavi, yeşil, kırmızı ve yakın kızıl ötesi olmak üzere dört spektral bant içermektedir. Uydu görüntülerine ek olarak analiz sonuçlarının değerlendirilmesinde kullanılan referans veri, arazi çalışması sırasında alandan görüntü çekim tarihiyle eş zamanlı olarak toplanan ürün bilgilerini içermektedir. Eş zamanlı toplanan referans parsellerinden 1012 adedi Ikonos, 914 adedi QuickBird-2 ve sırasıyla 631 ve 382 adedi Kompsat-2 Haziran ve Temmuz görüntülerine ait sınıflandırma sonuçlarını değerlendirmek amacıyla kullanılmıştır. Konu edilen referans parsellerine ait verinin yaklaşık %3'ü örnek alan seçiminde geri kalanı ise doğruluk analizlerinde kullanılmıştır. Görüntülere ait işlem düzeyleri standart olup veriler sensör kaynaklı radyometrik hataları giderebilmek için radyometrik olarak düzeltilmiştir.

3. YÖNTEM

3.1 Ortorektifikasyon

Ortorektifikasyon işlemlerinde kullanılmak üzere alanın sayısal yükseklik modeli Harita Genel Komutanlığı'ndan elde edilen 1:25.000 ölçekli sayısal haritalar kullanılarak üretilmiştir. Görüntülere ait ortorektifikasyon işlemi ticari bir yazılımda var olan 'sağlam yörünge modeli' kullanılarak Ikonos ve QuickBird-2 uydu görüntüleri için alandan homojen dağılımlı seçilen 20 yer kontrol noktası, Kompsat-2 görüntüleri için homojen dağılımlı sırasıyla 16 (Haziran) ve 19 (Temmuz) yer kontrol noktası kullanılarak gerçekleştirilmiştir. Ortorektifikasyon işlemi sonrasında elde edilen karesel ortalama hata miktarları Ikonos ve QuickBird-2 uydu görüntüleri için ±0.40 piksel civarında, Haziran ve Temmuz aylarına ait

Kompsat-2 görüntüleri için sırasıyla 0.34 piksel ve 0.47 piksel hesaplanmıştır.

3.2 Görüntü Sınıflandırma Yöntemleri

Çalışmada Çizge-tabanlı yaklaşım ve literatürde popüler tekniklerden olan DVM ve RO sınıflandırma yöntemleri incelenmiştir. Yöntemlere ait detaylar aşağıda verilmektedir.

3.2.1 Çizge-tabanlı Yaklaşım

Belirli bir sayıda düğüm (V) ve komşu düğümleri birbirine bağlayan kenarlardan (E) oluşan ağ yapısı bir çizgeyi $G = \{V, E\}$ tanımlamaktadır. Görüntü işleme çalışmalarında bir çizgedeki düğümler genellikle görüntüyü oluşturan piksellere karşılık gelmekte ve iki komşu piksel (p, q) arası yönsüz bir ilişki tercih edilmektedir. Düğümlerin birbirleriyle arasındaki kenarlar komşu-bağlar olarak tanımlanır ve düğümlerin birbirleriyle komşuluğunun bulunup bulunmadığı bilgisini içerir. Bütün kenarlar negatif olmayan maliyet değerleri taşırlar (c_{pq}) (Boykov ve Funka-Lea, 2006). Bir çizgede bulunan bütün düğümlerin her bir düğüme sadece bir uç-düğüm tarafından ulaşılabilecek şekilde kesilmesine çizge-kesme adı verilir.

Sınıflandırma problemleri bir enerji denklemini temel almakta ve sonuçta elde edilecek en uygun sınıflandırma, tanımlanan enerjiyi en aza indireyen sınıflandırma olarak elde edilmektedir (Boykov vd., 2006). Bu enerji denklemi (E) genel olarak iki farklı tipte enerjinin birleşimini içermekte ve aşağıdaki gibi tanımlanmaktadır:

$$E = \sum_{i=1}^M \varphi_i + \gamma \sum_{i=1}^M \sum_{j \in \mathcal{N}(i)} \varphi_{ij} \quad (1)$$

Yukarıdaki denklemde φ_i veri enerjisini, φ_{ij} düzleştirme enerjisini, γ düzleştirme katsayısını, M toplam piksel (düğüm) sayısını, $\mathcal{N}$ ise komşuluğu tanımlamaktadır. Eş. 1'de tanımlanan veri enerjisi bir piksele herhangi bir sınıfın atanmasının maliyetini belirtmektedir. Düzleştirme enerjisi ise komşu pikseller arası spektral benzerlikleri dikkate alarak o piksellere benzer sınıf etiketleri atanmasının maliyetini hesaplar.

Bu çalışmada her bir sınıfa ait veri maliyetlerinin hesaplanması için hem DVM (bkz. Bölüm 3.2.2) hem de RF (bkz. Bölüm 3.2.3) yöntemleri kullanılmıştır. Ayrıca farklı düzleştirme katsayısı değerlerinin sınıflandırma doğruluklarına etkisi incelenmiş ve en iyi doğruluk sonucu veren γ katsayısı değeri seçilmiştir. Düzleştirme enerjisi için ise iki farklı yaklaşım test edilmiştir. Birinci yaklaşım (Schindler, 2012) tarafından önerilen lineer karşıtlık fonksiyonudur:

$$\varphi_{ij} = \max(0, 1 - \frac{2 - \phi}{\max(I_g)} I_g(x_i, x_j)) \quad (2)$$

Eş. 2'de φ_{ij} düzleştirme enerjisini, I_g görüntü gradyanını (gradient), x_i ve x_j ise iki komşu pikseli, ϕ ise sabit bir değeri (ceza uygulamama sınırı) ifade etmektedir. Test verileri 4-bantlı görüntülerden oluştuğundan dört banttaki en yüksek gradyan değeri baz alınarak görüntü gradyanı elde edilmiştir. Düzleştirme enerjisi için ikinci yaklaşım için ise üstel bir fonksiyon kullanılmıştır (Rother vd., 2004):

$$\varphi_{ij} = \frac{e^{-\beta \|x_i - x_j\|}}{d_{ij}} \quad (3)$$

Eş. 2’de d_{ij} fonksiyonu x_i ve x_j piksellerinin görüntüde birbirlerine olan uzaklığını, $\| \cdot \|$ spektral değerler için Öklid mesafesini ve β ise her görüntü için $\beta = (2 \text{ mean}(\|x_i - x_j\|))^{-1}$ şeklinde otomatik olarak hesaplanan bir katsayıyı belirtmektedir.

Eş. 1’de tanımlanan enerji denklemi ikili sınıflandırma durumunda maksimum-akış yöntemi kullanılarak çözülebilmektedir (Boykov vd., 2004, Kolmogorov ve Zabih, 2004). 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.

3.2.2 Destek Vektör Makineleri (DVM)

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. Hiper-düzlemler iki sınıfı birbirinden etkin şekilde ayırabilmek için ‘mesafe (margin)’ denilen en yüksek açıklık seviyesine sahip olmalıdır (Vapnik 1995, 1998). Optimum hiper-düzlemler üzerinde kalan pikseller destek vektörlerini oluşturur ve görüntüdeki bilinmeyen piksellerin sınıflandırılmasında kullanılır (Tso ve Mather, 2009). DVM performansını çok boyutlu uzayda etkin hale getirebilmek için çeşitli kernel tipleri tanımlanmıştır (örn. Doğrusal, polinom, radyal tabanlı fonksiyon ve sigmoid) (Vapnik 1995).

3.2.3 Rastgele Orman (RO)

RO, ayırt edilebilen karar ağaç sınırlarının toplamı olarak ifade edilebilir. Ağaçlar, rastgele toplanan örnek piksellerin ve/veya bireysel ağaçların ayrı fonksiyonları yoluyla üretilir (Archer, 2008, Breinman, 2001). İşlemi gerçekleştirebilmek için geliştirilecek ağaç sayısı, düğümlerdeki bölünmeyi belirleyen değişken sayısı ve her bir yaprak için minimum gözlem sayısı olmak üzere 3 parametrenin tanımlanması gerekmektedir. Çalışmada RO sınıflandırma işlemini gerçekleştirebilmek için Sınıflandırma ve Regresyon Ağacı (Classification and Regression Trees (CART)) algoritması kullanılmıştır. RO hakkında detaylı bilgiye (Breinman, 2001) çalışması yoluyla ulaşılabilir. Literatür çalışmasında RO sınıflandırma algoritmasının tarımsal ürün sınıflandırması açısından az sayıda çalışmada kullanıldığı görülmüştür (örn. Rodriguez-Galiano vd., 2012, Long vd., 2013, Sonobe vd., 2014).


Diğer sınıflandırma yöntemlerinde olduğu gibi önerilen yöntem de kullanıcı tarafından tanımlanacak az sayıda parametreye ihtiyaç duymaktadır. Çalışmanın bu aşamasında sınıflandırma işlemlerinde kullanılacak en uygun parametre kombinasyonunu belirleyebilmek için bir dizi parametre testi gerçekleştirilmiştir. Bu işlem, sınıflandırma işlemlerinde kullanılan ana parametreler ile sınırlandırılmıştır. En güvenilir sınıflandırma sonuçları, parametre hassasiyet testleri yardımıyla bulunan optimum parametre kombinasyonu yoluyla elde edilmiştir.

DVM yönteminde kullanılmak üzere literatürde yer alan birçok çalışmada en iyi performansı sağlayan Radyal tabanlı kernel seçilmiştir (ör. Pal ve Mather, 2005, Yang, 2011, Kavzoglu ve Colkesen, 2010). Farklı görüntülere uygulanacak parametre kombinasyonunu genelleştirmek ve farklı görüntülere tek bir kombinasyon tanımlamak için yapılan testler ışığında Gamma = 0.5 ve Cost = 2100 olarak belirlenmiştir. RO sınıflandırması için geliştirilecek ağaç sayısı başlıca parametredir. Testler, az sayıda ağaç (≤ 4) tanımlandığı durumlar hariç sonuçların değişmediğini göstermiştir. Ön testler, RO sınıflandırması için kullanılan diğer parametrelerin ürün sınıflandırma doğruluğu üzerinde önemli bir etkisinin olmadığını göstermiştir.

4. TARTIŞMA

Görüntülere ait sınıflandırma sonuçları hata matrisleri yoluyla değerlendirilerek genel doğruluk ve kappa oranları ile her ürüne ait üretici ve kullanıcı oranları hesaplanmış ve elde edilen bulgular istatistiksel olarak değerlendirilmiştir. Şekil 1’de DVM ve RO sınıflandırma yöntemlerinin sonuçlarının Çizge tabanlı yöntemle ait farklı düzleştirme yöntemleri kullanılarak elde edilen sınıflandırma performans grafikleri verilmiştir. Şekil 1 çizge tabanlı yöntemin ham sınıflandırma performanslarını tüm görüntüler için artırdığını açıkça göstermektedir. Şekil 1’deki sonuçlar çizge tabanlı DVM yönteminin üstel düzleştirme fonksiyonu kullanıldığında en iyi sonucun elde edildiğini göstermektedir. Bu nedenle bu bölümde DVM yöntemine ait sonuçlar irdelenmiştir (Tablo 1). Buna göre, hesaplamalar, en yüksek spektral karışmanın şeker pancarı, domates, mera ve mısır ürünlerinde olduğunu göstermiştir. Bu karışmanın başlıca nedenleri arasında ürünlerin benzer spektral özellik göstermesi ve Haziran ayına ait Kompasat-2 verisinde görülen bitkilerin gelişim evrelerinin ilk aşamasında olmasından dolayı toprağa ait spektral değerler ile karışması olarak göstermek mümkündür.

Şekil 2’de İkonos görüntüsü, ham DVM sonucu, DVM’nin lineer karşıtlık ve üstel fonksiyonu kullanılarak üretilen tematik haritaları verilmektedir. İkonos görüntüsü için kullanılan referans piksel sayısı 1.840.093’dır. En yüksek karışma oranı mera ve mısır bitkileri arasında gözlenmiştir. Hata matrisi incelendiğinde 257.703 adet mera pikselinin sadece 153.932 adedinin mera olarak sınıflandırıldığı tespit edilmiştir. Benzer



Şekil 1. Sınıflandırma sonuçlarına ait performans grafiği
Tablo 1. Kullanılan veri setine ait çizge tabanlı yöntemin (DVM ve üstel düzleştirme fonksiyonu) sınıflandırma sonuçları (%).

	İkonos (Temmuz)		Kompasat-2 (Temmuz)		QuickBird-2 (Ağustos)		Kompasat-2 (Haziran)	
Sınıflar	ÜD	KD	ÜD	KD	ÜD	KD	ÜD	KD
Mısır	82,1	97,1	88,9	54,3	95,7	95,5	18,6	27,7
Mera	97,6	59,7	95,9	95,3	93,2	81,6	71,1	47,8
Pirinç	94,8	98,3	93,1	99,1	74,0	93,5	98,3	85,5


Şeker p.	96,3	60,7	84,2	99,3	93,9	72,7	86,6	84,6
Buğday	82,6	96,5	94,5	97,7	93,8	91,3	66,6	85,1
Domates	87,6	83,2	96,2	28,3	88,2	92,4	21,1	96,2
GD	86,37	93,32	90,78	74,43				
Kappa	82,65	90,95	88,14	63,58				

ÜD: Üretici Doğruluğu, KD: Kullanıcı Doğruluğu, GD: Genel Doğruluk

durum, spektral yansıma değerlerinin benzerliğinden dolayı şeker pancarı ve domates ürünleri arasında da görülmüştür. Sonuçlar, sınıflandırma yönteminin büyük alanları kapsayan sınıflar için yüksek olduğunu göstermiştir (%97'e varan oranlarda ve genellikle %82'nin üstünde). Düşük doğruluk değerlerine ait sınıf oranlarının ön bilgi kullanımıyla giderilebileceği öngörülmektedir.

Kompsat-2 Temmuz ayı görüntüsüne ait sınıflandırma sonuçlarını değerlendirmek için 901.107 piksel kullanılmıştır. Sonuçlar, Ikonos görüntüsüne ait sonuçlarla benzer özellik göstermektedir (Şekil 3). En yüksek karışma spektral benzerlik özelliklerinden ötürü domates ve şeker pancarı bitkilerinde gözlenmiştir. Bununla birlikte pirinç ve buğday bitkileri arasında da önemli spektral karışmalar tespit edilmiştir. Ürünler için hesaplanan kullanıcı doğrulukları genellikle yüksek (>%84) olmakla birlikte bazı ürün sınıflarının düşük kullanıcı doğruluğuna sahip olduğu görülmüştür.


QuickBird-2 (Ağustos) görüntüsü için değerlendirmelerde kullanılan referans piksel sayısı 4.811.904 dür. Başlıca spektral karışmaların pirinç-buğday ve şeker pancarı-domates ürünleri arasında olduğu gözlenmiştir (Şekil 4). Büyük alan sınıfları için hesaplanan kullanıcı doğruluğunun %72 üstünde olduğu




Şekil 3. (a) Kompsat-2 (Temmuz - 2008) çok-bantlı görüntüsü, (b) ham DVM, (c) DVM-lineer karşıtlık, (d) DVM-üstel fonksiyon sonucu

görülmüştür. Buna karşın ürünlere ait kullanıcı doğrulukları daha yüksektir (pirinç: %74 ve diğerleri >88%). Özellikle mısır sınıfı için hesaplanan üretici ve kullanıcı doğrulukları sırasıyla 95,7% ve 95,5%'dir. Bu sonuçlar sadece dört spektral bant kullanılarak yapılan bir sınıflandırma işlemi için oldukça dikkat çekicidir.

Diğer üç test görüntüsüyle karşılaştırıldığında Haziran ayına ait Kompsat-2 görüntüsü için hesaplanan karışma oranlarının oldukça yüksek olduğu görülmüştür (Şekil 5). Bunun nedeni ürünlerin erken gelişim evrelerinde olmasından kaynaklanan spektral karışmalardır. Çünkü bu evrede ürünler, parsel alanlarının tamamını örtmediği için toprak görünür hale gelmektedir. Ayrıca ürünlerin erken gelişim evrelerinde yansıttıkları spektral değerler de karışmalara neden olabilmektedir. Düşük sonuçların bir diğer nedeni de, Haziran




Şekil 2. (a) Ikonos (2004) çok-bantlı görüntüsü, (b) ham DVM, (c) DVM-lineer karşıtlık, (d) DVM-üstel fonksiyon sonucu




Şekil 4. (a) QuickBird-2 (2004) çok-bantlı görüntüsü, (b) ham DVM, (c) DVM-lineer karşıtlık, (d) DVM-üstel fonksiyon sonucu



(a) (b)



(a) (b)



Şekil 5. (a) KompSat-2 (Haziran - 2008) çok-bantlı görüntüsü, (b) ham DVM, (c) DVM-lineer karşıtlık, (d) DVM-üstel fonksiyon sonucu

görüntüsüne ait mısır ve domates ürünleri için toplanan örnek alan ve referans piksel sayısının yetersizliğidir. KompSat-2 Haziran görüntüsü için toplanan örnek alanlara ait piksel sayısı 1.186.694'tür. Sonuçlar, küçük ürün sınıflarının (mısır ve domates) doğruluklarının oldukça düşük olduğunu göstermiştir. Bunun yanında mera ve buğday ürünleri arasındaki karışım oranı da yüksektir. Diğer taraftan, bazı ürün sınıflarına ait örnek ve referans piksel sayılarının düşük olmasına karşın büyük ürün sınıfları için hala %85'lere varan yüksek üretici ve kullanıcı doğruluklarının hesaplanabildiği gözlenmiştir.

Hesaplanan doğruluk oranları ışığında tüm görüntülere ait performanslar karşılaştırıldığında KompSat-2-Temmuz görüntüsünün en yüksek değerlere (Genel doğruluk: 93.32% ve Kappa: 90.95%) ulaştığı gözlenmiştir.

5. SONUÇLAR

Bu çalışmada tek tarihli ve yüksek çözünürlüklü çok-bantlı görüntülerin ürün sınıflaması üzerindeki başarısı incelenmiştir. Tüm sonuçlar içinde çizge tabanlı DVM yöntemi üstel düzleştirme fonksiyonu ile kullanıldığında en yüksek sonucu sağlamıştır. Fakat DVM yönteminin görüntüler üzerindeki yüksek işlem süresi göz ardı edilmemelidir. Analizler sonucunda çizge tabanlı düzleştirme yönteminin genel doğruluk oranlarını %10'a kadar artırdığını gözlenmiştir. Sonuçlar, üstel filtre fonksiyonunun lineer karşıtlık filtre fonksiyonu sonuçlarından yüksek olduğunu ($\approx 2\%$) göstermiştir.

Bu çalışma aynı zamanda ürün gelişim evrelerine bağlı olarak görüntüleme tarihinin önemine de dikkat çekmektedir. Birçok ürün türü için en yüksek olgunlaşma evresinde çekilen görüntülerin en yüksek sonucu sağladığı görülmüştür. Bu sayede topraktan yansiyabilecek spektral değerler önlenilecek ve ürünlerin parsel kapama oranlarının en yüksek seviyeye ulaşması sağlanarak spektral karışmaların önüne geçilebilecektir. Bu çalışmada ürün haritalama amacıyla Haziran ayı içinde çektilen görüntülerin Temmuz ve Ağustos aylarına nazaran daha düşük sonuçlar ürettiği gözlenmiştir. Fakat ürün gelişiminin, farklı ürün türleri, farklı coğrafi bölgeler ve zaman için farklı davranışlar göstereceği de dikkate alınması gereken önemli bir noktadır. Örneğin sınıflandırılması düşünülen farklı ürün türlerinin tamamı için uygun bir görüntüleme periyodu olmayabilir veya bu zaman aralığı çok dar olabilir. Bu gibi durumlarda çok-tarihli görüntü kullanımı ve/veya farklı tip sensörlerden (örn. SAR) elde edilen görüntülerin kullanımını yoluna gitmek doğruluk seviyelerini daha da yukarıya taşıyabilecektir.

Ürnlere ait sınıflandırma doğrulukları incelendiğinde en belirgin karışmanın mera-mısır, pirinç-şeker pancarı, domates-şeker pancarı ve mısır-şeker pancarı sınıfları arasında olduğu

gözlenmiştir. Başlıca karışma nedenleri arasında sınıflar arasındaki spektral benzerlikler ve görüntülere ait spektral çözünürlüğün sınırlı olması (mavi, yeşil, kırmızı ve yakın kızıl ötesi) sayılabilir. Daha fazla örnek alan toplamak veya ek spektral bant kullanımı ile nesnelere ilişkin ek özelliklerinin bütünleştirilmesi ile bu eksikliğin belli bir oranda giderilebileceği öngörülmektedir.

TEŞEKKÜR

Çalışmada kullanılan İkonos ve QuickBird-2 görüntüleri ODTÜ'de yürütülen BAP-08-11-DPT2002K120510 numaralı ÖYP projesi tarafından desteklenmiştir. Yazarlar, İkonos ve QuickBird-2 görüntülerine ait referans verilerin toplanmasındaki katkılarından dolayı Prof. Dr. Mustafa Türker'e teşekkürlerini sunar. KompSat-2 uydu görüntüleri yine ODTÜ'de yürütülen DAP-2008-07-02-07 projesi tarafından desteklenmiştir. Yazarlar, KompSat-2 görüntülerine ait referans verilerinin toplanmasındaki yardımlarından dolayı Karacabey Ovası Sulama Birliği çalışanlarına teşekkürlerini sunar.

KAYNAKLAR

- Archer, K. J., 2008. Empirical characterization of random forest variable importance measure. *Computational Statistics, Data Analysis*, 52, syf. 2249-2260.
- Boykov, Y., Funka-Lea, G., 2006. Graph cuts and efficient N-D image segmentation. *International Journal of Computer Vision*, 70(2), syf. 109-131.
- Boykov, Y., Veksler, O., Zabih, R., 2001. Fast approximate energy minimization via graph cuts. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11), syf. 1222-1239.
- 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), syf. 1124-1137.
- Breiman, L., 2001. *Random Forests, Machine learning*. Kluwer Academic Publishers: the Netherlands, pp. 5-32.
- Kavzoglu, T. Colkesen I., 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144, syf. 73-82.
- Kolmogorov, V., Zabih, R., 2004. What energy functions can be minimized via graph cuts?. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(2), syf. 147-159.
- Long, J. A. Lawrence, R. L. Greenwood, M. C. Marshall, L. Miller, P. R., 2013. Object-oriented crop classification using multitemporal ETM+ SLC-off imagery and random forest. *GIScience & Remote Sensing*, 50, syf. 418-436.
- McLachlan, G., Peel, D., 2000. *Finite Mixture Models*. Hoboken. NJ: John Wiley & Sons, Inc.
- Orchard, M.T., Bouman, C.A., 1991. Color Quantization of Images. *IEEE Transactions on Signal Processing*, 39(12), syf. 2677-2690.

Pal, M., Mather, P. M. 2005. Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26, syf. 1007–1011.

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

Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M. Rigol-Sanchez, J. P. 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, syf. 93–104.

Sonobe, R., Tani, H., Wang, X., Kobayashi N., Shimamura, H. 2014. Random forest classification of crop type using multi-temporal TerraSAR-X dual-polarimetric data. *Remote Sensing Letters*, 5, syf. 157–164.

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

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

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

Yang, X., 2011. Parameterizing support vector machines for land cover classification. *Photogrammetric Engineering and Remote Sensing*, 77, pp. 27–37.