

[1086]

HİPERSPEKTRAL GÖRÜNTÜLERİN NESNE-TABANLI SINIFLANDIRILMASINDA BOYUTSALLIK PROBLEMİ VE PARAMETRE SEÇİMİ

Taşkın KAVZOĞLU¹, Hasan TONBUL², Merve YILDIZ ERDEMİR³, İsmail ÇÖLKESEN⁴

¹Prof. Dr., Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, 41400, Kocaeli, kavzoglu@gtu.edu.tr

²Arş. Gör., Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, 41400, Kocaeli, htonbul@gtu.edu.tr

³Arş. Gör., Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, 41400, Kocaeli, m.yildiz@gtu.edu.tr

⁴Yrd. Doç Dr., Gebze Teknik Üniversitesi, Harita Mühendisliği Bölümü, 41400, Kocaeli, icolkesen@gtu.edu.tr

ÖZET

Günümüzde, hiperspektral görüntülerin miktarındaki artışa paralel olarak nesne-tabanlı sınıflandırma yaklaşımı arazi kullanımı ve arazi örtüsü sınıflarının belirlenmesinde daha önemli bir hale gelmiştir. Hiperspektral görüntülerin yüksek boyutlu veri içermesi ve genellikle sınırlı sayıda eğitim verisi bulunmasından dolayı, istatistik tabanlı parametrik metotlar yetersiz kalmaktadır. Nesne-tabanlı sınıflandırma ise semantik bilgiyi pikselleri tekil olarak ele almak yerine görüntü objelerini ele almakta ve daha kapsamlı bir değerlendirme yapmaktadır. Bu çalışmada, AVIRIS sensörüne ait Indian Pine hiperspektral veri seti kullanılmıştır. Hiperspektral görüntü boyutlarının büyük olması sebebiyle sınıflandırma işlemi öncesinde önemli ve baskın özelliklerin çıkartılması gerekmektedir. Bu kapsamda, 200 bantlı Indian Pine görüntüsüne Temel Bileşenler Analizi (TBA) boyut indirgeme işlemi uygulanmış ve verinin %98.5'ünü temsil eden ilk 19 temel bileşen kullanılmıştır. Nesne-tabanlı sınıflandırma işleminde, TBA ile elde edilen görüntü kullanılarak optimum ölçek parametresi 29 olarak belirlenmiş ve çoklu-çözünürlüklü segmentasyon işlemi gerçekleştirilmiştir. Optimum ölçek parametresi ölçek parametresi tahmin (ESP) aracı ile belirlenmiştir. Piksel-tabanlı (en büyük benzerlik sınıflandırıcısı) ve nesne-tabanlı sınıflandırma (nearest neighbor) yöntemleri uygulanarak sınıflandırma performansları karşılaştırılmış ve analiz edilmiştir. Sınıflandırma doğruluk analizleri oluşturulan test verisi ile gerçekleştirilmiş, genel doğruluk ve kappa katsayısı değerleri hesaplanmıştır. Çalışma sonucunda, piksel-tabanlı sınıflandırma yaklaşımı ile %72,2 genel doğruluk elde edilirken, nesne-tabanlı sınıflandırma yaklaşımı ile %78,3 genel doğruluk elde edilmiştir. Hiperspektral veri seti boyutunun indirgenmesiyle (yaklaşık % 91 oranında) nesne-tabanlı sınıflandırmanın sınıflandırma doğruluğundaki artış % 6 seviyelerine ulaşmıştır. Ayrıca, McNemar's testi kullanılarak sonuçların performans farklılıklarının istatistiksel olarak anlamlı olduğu tespit edilmiştir.

Anahtar Sözcükler: Hiperspektral görüntü, Nesne-tabanlı görüntü analizi, Segmentasyon, Sınıflandırma, Temel bileşenler analizi (TBA)

ABSTRACT

DIMENSIONALITY PROBLEM AND PARAMETER SELECTION IN OBJECT-BASED CLASSIFICATION OF HYPERSPECTRAL IMAGES

Nowadays, with increasing number of hyperspectral imagery, object-based classification has gained considerable importance for determining land use and land cover classes. Statistical parametric classifiers have become ineffective for hyperspectral classification because of the high-dimensional data and limited number of training samples. Object-based classification acquires semantic information using image objects instead of single pixels and produce more comprehensive image analysis. In this study, Indian Pine hyperspectral data set which belongs to AVIRIS sensor was used. Due to the high-dimensional hyperspectral image, essential and dominant features should be determined before the classification process. In this context, Principal Component Analysis was applied to the data set and first 19 principal components which represent 98.5% of the data was used. In object-based classification, optimum scale parameter was determined 29 and multi-resolution segmentation was implemented using PCA derived data set. Scale parameter was determined by using Estimation of Scale Parameter (ESP) tool. Pixel based classification (maximum likelihood) and object-based (nearest neighbour) approaches were applied and classification performances were compared in detail. Classification accuracy analysis was performed using the generated test data and the overall accuracy and kappa coefficient were calculated. As a result, pixel-based classification approach produced 72.2% overall accuracy while object-based approach produced 78.3% overall accuracy. It was observed that using object-based classification by reducing the dimensions of hyperspectral data set (decreased by about 91 %) increased classification accuracy by 6%. Moreover, MCNemar's test results showed that the performance differences of the approaches were statistically significant.

Keywords: Hyperspectral image, Object-based image analysis, Segmentation, Classification, Principal Component Analysis (PCA)

1.GİRİŞ


Son yıllarda uzaktan algılama alanında hiperspektral veri kullanımı yeni sensörlerin de katkısıyla önemli ölçüde artış göstermiştir. Yüksek spektral ve konumsal çözünürlüğe sahip olan hiperspektral görüntüler, nesnelere ayırt edebilme kapasitesini artırarak görüntü işleme ve sınıflandırma aşamalarında kullanıcılara büyük avantaj sağlamaktadır. Bu avantaj genellikle hiperspektral görüntülerin sahip olduğu özgün ve dar spektral bantlarındaki emilim ve yansıtım belirleme kapasitesinden kaynaklanmaktadır (Kamal ve Phinn, 2011). Buna karşın, birçok analizin daha etkin yapılabilmesi için ele alınan problemle ilgisi az olan bantların elimine edilmesi gerekmektedir (Bajcsy ve Groves, 2004; Datta vd., 2014).Yüksek boyutlu veriler için istatistik tabanlı sınıflandırıcılar kullanılması durumunda eğitim veri seti boyutu ihtiyacı artmakta, birçok uygulama için karşılanamayacak miktara ulaşmaktadır. Literatürde parametrik sınıflandırıcıların kullanımında her bir sınıf için bant sayısının en az 30 katı kadar örnek gerektiği yönünde genel bir yaklaşım vardır (Mather, 1999). Bu kapsamda, Temel Bileşenler Analizi (TBA) yaygın olarak kullanılan boyut indirgeme yöntemleri arasında gelmektedir. Bu yöntem ile hiperspektral görüntülerin içerdiği yüksek korelasyona sahip spektral bantlar önemli bir veri kaybı olmadan azaltılabilmektedir (Agarwal vd., 2007; Regan ve Srivatsa, 2015).

Günümüzde kullanılan uydu görüntülerinin içerdiği spektral bilgi ve çözünürlüğün artmasına paralel olarak piksel-tabanlı yaklaşım yetersiz kalmaktadır. Piksel-tabanlı sınıflandırmada, pikseller göstermiş oldukları spektral benzerliklere göre ilgili sınıflara atanmakta ve diğer dokusal özellikler göz önünde bulundurulmamaktadır. Ayrıca, literatürde tuz-biber (salt and pepper) etkisi olarak bilinen tematik haritalardaki gürültü oranının artması da önemli bir sorun teşkil etmektedir (Blaschke et al., 2000). Nesne-tabanlı sınıflandırma, piksel-tabanlı sınıflandırmanın aksine pikselleri tek tek ele almak yerine komşu pikselleri doku, şekil, alan gibi özelliklerine bağlı olarak gruplandırmakta ve görüntü nesnelere oluşmaktadır. Nesne-tabanlı sınıflandırmanın ilk ve en önemli aşaması görüntü nesnelere belirlendiği segmentasyon aşamasıdır. Geleneksel segmentasyon metotları piksel tabanlı, kenar tabanlı ve bölge tabanlı segmentasyon olmak üzere 3'e ayrılmaktadır. Bölge tabanlı segmentasyon metotları arasında yer alan Çoklu-çözünürlük yöntemi en çok kullanılan yöntemler arasında yer almaktadır. Bu yöntem, benzer spektral özellik gösteren komşu piksellerin gruplandırılmasıyla nesnelere oluşturulmasına ve farklı ölçek seviyeleri kullanılarak nesne hiyerarşisi üzerinden çalışılmasına imkân tanımaktadır (Benz vd., 2004). Çoklu-çözünürlük segmentasyon aşamasında kullanıcı tarafından belirlenmesi gereken parametreler vardır. Bunlar içinde araştırmacıların hemfikir olduğu görüş, ölçek parametresinin en önemli ve doğruluk üzerinde en çok etkiye sahip parametre olduğudur. Bu çalışmada, segmentasyon aşamasında ölçek parametresi, Drăgut vd. (2010) tarafından geliştirilen ölçek parametresi tahmini (ESP) aracı ile belirlenmiştir.

Bu çalışmanın iki temel objektifi bulunmaktadır; i) Indian Pine hiperspektral veri setinin TBA yardımı ile boyutsal olarak indirgenmesi ve sınıflandırmaya katkısı olacak bileşenlerin belirlenmesi, ii) boyut indirgemesi uygulanmış görüntüye piksel-tabanlı ve nesne-tabanlı sınıflandırma yöntemleri uygulayarak performanslarının karşılaştırılmasıdır. Bu karşılaştırma hata matrisinden hesaplanan doğruluk kriterleri verileri ile analiz edilmiş ve performans farklılıkları istatistik test ile analiz edilmiştir.

2.ÇALIŞMA ALANI VE VERİ SETİ

Bu çalışmada, AVIRIS sensörüne ait 200 spektral bant, 16 bit radyometrik ve 20 metre konumsal çözünürlüğe sahip, 145 x 145 boyutlarında ve 16 sınıftan oluşan Indian Pine hiperspektral veri seti (Şekil 1) kullanılmıştır (Li vd., 2015). Görüntü, ABD' nin Kuzeybatı Indiana bölgesine ait olup 2/3 lük bölümü tarım alanlarından geri kalan 1/3 lük bölümü ise ormanlık ve otsu alanlardan oluşmaktadır. Ücretsiz olarak temin edilebilen bu veri seti birçok yayında yeni metot ve yaklaşımların test edilmesinde kullanılan örnek bir veri seti konumundadır.



Şekil 1. Indian Pines AVIRIS hiperspektral veri seti

3.METODOLOJİ

3.1.Piksel-Tabanlı Sınıflandırma

Piksel-tabanlı sınıflandırma piksellere ait spektral bant değerleri ve piksellerin birbirleriyle olan komşuluk ilişkilerine bağlı olarak gerçekleştirilmektedir. Piksel-tabanlı sınıflandırma yöntemi kontrolsüz sınıflandırma ve kontrollü sınıflandırma yöntemi olmak üzere ikiye ayrılmaktadır. Kontrolsüz sınıflandırma yöntemi, çalışma alanına ait yeterli örnekleme verisi veya istatistiksel bilgi çıkarımı yapılamadığı durumlarda spektral olarak ayrılabilen sınıfları belirlemek ve bilgi çıkarımı amacıyla yapılır. Kontrollü sınıflandırma yönteminde ise, çalışma alanına ait yeryüzü karakteristiğini yansıtan yeterli sayıda örnek bölgeleri (test alanlar) kullanarak, sınıflandırılacak her bir nesne için spektral özellik çıkartımı yapılmaktadır. Test alanlarının örneklendiği özellik bilgileri görüntü üzerinde uygulanarak, her bir piksel için hesaplanan olasılık değerlerine bağlı olarak en çok benzer olduğu sınıfa atanmaktadır. En yakın uzaklık ve En büyük benzerlik sınıflandırıcısı en yaygın kullanılan kontrollü sınıflandırma yöntemleri arasında yer almaktadır.

Bu çalışmada, en büyük benzerlik sınıflandırıcısı yöntemi piksel-tabanlı sınıflandırma işlemi aşamasında kullanılmıştır. Kullanılan yöntem, sınıflar için eş olasılık eğrilerinin tanımlanmasına ve sınıflandırılacak piksellerin üyelik olasılığı en fazla olan sınıfa atanması ilkesine dayanmaktadır. En büyük benzerlik sınıflandırıcısı yöntemine ait işlem aşaması aşağıda ifade edilmiştir (Asmala ve Shaun, 2012).

- Çalışma alanına ait arazi sınıf sayısının belirlenmesi
- Belirlenen sınıflara ait eğitim piksellerinin seçilmesi. Genellikle, normal dağılım kabulü ile sınıflar ayrılır.
- Elde edilen eğitim pikselleri daha sonra her bir sınıfa ait ortalama vektör ve kovaryans matrisi hesaplanmasında kullanılır.
- Son olarak, her bir piksel ait olduğu düşünülen sınıfa atanır veya bilinmeyen olarak etiketlenir.

En büyük benzerlik sınıflandırıcısı, parametre tahmini açısından tutarlı olmasına karşın dezavantajları fazla olan bir yöntemdir. En önemli dezavantajlarının başında, istatistiksel bir yöntem olması sebebiyle artan veri set boyutuna bağlı olarak eğitim seti ihtiyacının artması ve her bir sınıfa ait örneklerin normal dağılımda olduğu kabulü gelmektedir. Ayrıca, üretilen tematik haritaların Coğrafi Bilgi sistemler (CBS) veritabanlarında kullanımı görüntü kalitesinden dolayı sınırlıdır.

3.2.Nesne-Tabanlı Sınıflandırma

Nesne-tabanlı sınıflandırmada görüntüyü oluşturan milyonlarca piksel yerine, bu piksellerin belirli kriterler dâhilinde gruplandırılmasıyla oluşturulan görüntü nesnelere sınıflandırılmaktadır. Nesnelere komşuluk, doku, şekil, boyut gibi özelliklerinden faydalanarak çeşitli analizlerin yapılabilmesi bu sınıflandırma yaklaşımının önemli avantajlarından birisidir. Nesne tabanlı sınıflandırmanın ilk aşaması olan segmentasyon işlemi görüntü nesnelere oluşturulmaktadır. Segmentasyon parametrelerinin (ölçek, şekil, bütünlük parametreleri ve bant ağırlıkları) seçimi, gerçek arazi nesnesine uygun nesne boyutunun belirlenmesi açısından büyük öneme sahiptir. Belirtilen parametreler doğru seçilmediği takdirde aşırı segmentasyon veya eksik segmentasyon olarak adlandırılan, olması gerekenden büyük veya küçük segmentler üretilmektedir. Birçok yazar tarafından ifade edildiği gibi, Segmentasyon kalitesinin analizi yüksek doğruluklu sınıflandırma için bir ön şart konumundadır (Kim vd., 2009; Marpu vd., 2010; Kavzoğlu vd., 2016b).

Ölçek parametresi nesne boyutunu belirleyen en önemli parametredir (Kim et al., 2011; Myint et al., 2011). Bu sebeple, optimum ölçek parametresinin belirlenmesi çalışmalarda önemli bir problem olarak ortaya çıkmaktadır (Kavzoğlu ve Yıldız, 2014; Kavzoğlu vd., 2016a). Literatürde, ölçek parametresi genellikle deneme yanılma yoluyla belirlenmektedir (Hoffman vd., 2008). Ancak optimum ölçek parametresi belirlenmesine yönelik geliştirilmiş birkaç metod ve yaklaşım bulunmaktadır. Literatürde genel olarak kabul görmüş bir metod bulunmamasına karşın Drăgut vd. (2010) tarafından geliştirilen ölçek parametresi tahmini (ESP) aracı en sık kullanılan yaklaşımlardan biridir. ESP aracı, eCognition Developer yazılımı üzerinde çalışan ölçek parametresinin hızlı tahminine yardımcı olan bir araçtır. Kullanıcının tanımladığı artış miktarına göre görüntüyü otomatik olarak segmentlere ayırır ve her obje aşamasında objeler arasında standart sapmaların ortalaması olarak lokal varyansları hesaplar (Kalkan, 2011). Her bir ölçek parametre değeri için hesaplanan lokal varyans grafiği çizdirilir. Grafik, lokal varyansın tek başına anlamlı nesnelere belirtmeyeceğini göstermektedir. Lokal varyansın değişim oranlarındaki eşik değerleri hangi ölçek parametresinde anlamlı objelerin segmentasyonun yapılacağını belirler (Drăgut vd., 2010). Her bir ölçek parametresi için hesaplanan lokal varyans değerinin değişim oranının Eşitlik 1'e göre belirlenmesi sonucunda bir LV-RoC grafiği elde edilmektedir. LV-RoC grafiği ani iniş çıkışlardan oluşan pikler şeklindedir ve grafikte ani değişimin görüldüğü ilk pik seçilebilecek optimum ölçek parametresini göstermektedir.

$$RoC = \left[\frac{L-(L-1)}{L-1} \right] * 100 \quad (1)$$

Burada, L hedef nesnenin lokal varyansını, $L-1$ bir sonraki alt nesne seviyesinin lokal varyansını ifade etmektedir. LV-RoC grafiğine göre değişim farkının en belirgin görüldüğü ölçek değerinin optimum ölçek parametresi olması kabulü yapılmaktadır. ESP-2 aracı (Drăgut et al., 2014) bir önceki versiyonun nesnelere otomatik olarak da belirlenmesini sağlayan geliştirilmiş bir versiyonudur. Ayrıca görüntünün lokal varyansını hesaplarken, ESP-1 de tek bant kullanımının aksine görüntünün maksimum 30 bantını kullanarak hesap yapmaktadır. Böylelikle çok bantlı görüntülerin analizlerinde ESP-2 daha iyi sonuç vermektedir. Burada belirtilmesi gereken önemli bir husus, bu çalışmada kullanılan 200 bantlı hiperspektral görüntünün tüm bantlarının ESP-2 programında kullanılamayacağı ve bir boyut indirgemesinin zorunlu olduğudur.

3.3. Temel Bileşen Analizi

Temel bileşen analizi uzaktan algılama alanında yoğun şekilde kullanılan istatistiksel bir işlem olup, aralarında yüksek korelasyon bulunan çok değişkenli verileri, aralarında korelasyon olmayan yeni bir koordinat sistemine dönüştüren doğrusal bir dönüşüm yöntemidir. Orijinal veriler için dik olan en büyük varyans yönleri bulunup orijinal veriler bu koordinat sisteminde gösterilir. Bu yöntemde, ilk bileşen toplam değişkenliğin en fazla olduğu değişken iken sonraki değişkenlerde değişkenlik giderek azalmaktadır.

Temel bileşen analizindeki esas amaç en büyük varyansın olduğu yöndeki izdüşüm vektörlerinin belirlenmesidir. Elde edilen izdüşüm vektörleri farklı bir uzayda birbirinden bağımsız değerler olarak ifade edilir. İzdüşüm vektörleri veriden elde edilen kovaryansa özdeğer - özvektör dönüşümü yapılarak elde edilmektedir. Özdeğerler büyükten küçüğe doğru sıralanır. Bu sıralı d tane özdeğerlere karşılık gelen özvektörlerden ilk n tanesi kullanılarak matrisin sütunları dizilir. Böylece en iyi izdüşümü gerçekleştiren izdüşüm matrisi elde edilir (Aydoğdu vd., 2015).

4. DENEYSEL SONUÇLAR

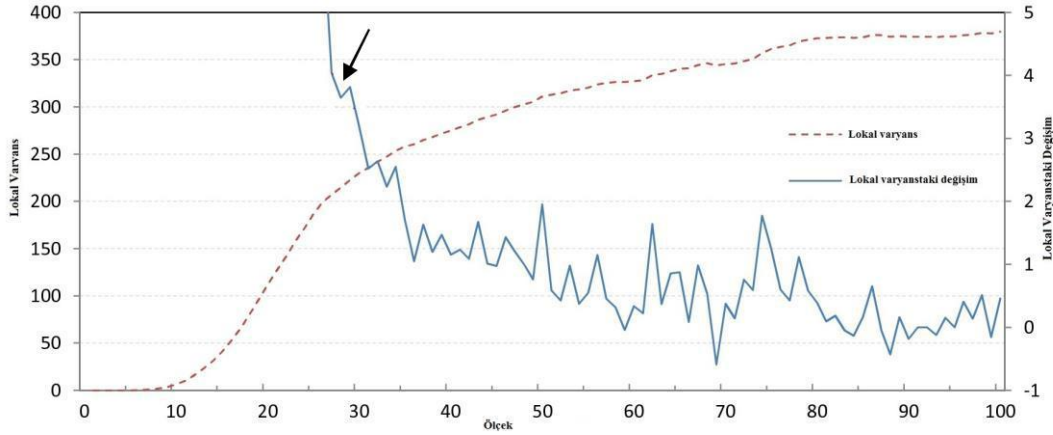
Bu çalışmada, NASA tarafından bilimsel araştırmalar yapılması amacı ile kullanıcılara ücretsiz olarak sunulan hiperspektral AVIRIS algılayıcısı ile elde edilmiş olan 200 bantlı Indian Pine hiperspektral veri seti kullanılmıştır. Orijinal Indian Pine görüntüsünde 16 sınıf bulunmaktadır, fakat bazı sınıfların örnek sayısının az olmasından dolayı bu çalışmada 9 sınıf kullanılmıştır. Çalışmada kullanılan sınıflar: mısır-işlenmemiş toprak, mısır-az işlenmiş toprak, saman, çayır-ağaç, çayır-otlak, soya fasülyesi-işlenmemiş toprak, soya fasülyesi-az işlenmiş toprak, soya fasülyesi ve ormanlık alan olarak gösterilmiştir. Orijinal veri setinde kullanılan piksel sayıları Çizelge 1’de sunulmuştur. Eğitim alanları referans veri seti (ground truth) olarak tanımlanan bölgelerin yaklaşık %30’unu kapsayacak şekilde her bir sınıf için belirlenmiştir. Test alanına ait görüntünün nesne-tabanlı sınıflandırma işlemi Definiens eCognition (9.1) yazılımında, piksel-tabanlı sınıflandırma aşaması ise ENVI (5.1) yazılımında gerçekleştirilmiştir.

Çizelge 1. Indian Pine Görüntüsü sınıflarına ait örnek piksel sayıları

Sınıf	Örnek Sayısı
Mısır-işlenmemiş toprak	1428
Mısır-az işlenmiş toprak	830
Saman	478
Çayır-ağaç	730
Çayır-otlak	483
Soya fasülyesi- işlenmemiş toprak	972
Soya fasülyesi- az işlenmiş toprak	2455
Soya fasülyesi	593
Ormanlık alan	1265

Nesne-tabanlı sınıflandırma işlemi için ilk olarak segmentasyonda kullanılacak olan ölçek parametresinin belirlenmesi işlemi gerçekleştirilmiştir. Çalışmada kullanılan veri setinin 200 bant olması sebebiyle bu parametrenin belirlenmesi için ESP-2 aracının kullanılmasına karar verilmiştir. Fakat buradaki problem görüntüye ait bant sayısının ESP-2 nin hesapladığı bant sayısından fazla olmasıdır. Ayrıca, eldeki veri seti ile sınırlı örnek sayısından dolayı sağlıklı bir sınıflandırma yapmak mümkün değildir. ESP-2’de ilk 30 bantın kullanılmasının yerine TBA ile sınıflandırma problemi için en anlamlı bantların tespitinin yapılması uygun görülmüştür. 30p kuralına göre, her bir sınıf için $30 \times 200 = 6000$ adet piksel gerekmektedir. Ancak bu sayıda bir örnek ile istatistiksel olarak anlamlı bir uygulama yapılabilir. Oysa mevcut veri seti içerisinde, saman sınıfı için eğitim ve test aşamalarında kullanılmak üzere toplam 478 piksel örneği bulunmaktadır. Parametrik olmayan gelişmiş sınıflandırıcılar için bu şartın geçerli olmadığı söylenebilir. Böylelikle ilk olarak Indian Pine görüntüsüne TBA uygulanarak boyut azaltma işlemi yapılmış ve verinin %98.5’ünü temsil eden ilk 19 temel bileşen kullanılmıştır. Böylelikle, veri setinin boyutu yaklaşık % 91 oranında azaltılmıştır. Görüntünün en uygun ölçek parametresinin

ESP-2 ile hesaplanan LV-RoC grafiğinde deęişim oranının ilk zıplamasının gösterdiği 29 deęerinde seçilmiştir (Şekil 2). Çalışmada sadece ESP-2 aracının ürettiği grafik deęerlerinden yararlanılmıştır. Çoklu-çözünürlüklü segmentasyon işlemi ile nesnelere üretilmiştir. Ardından görüntü en yakın komşuluk sınıflandırıcısı ile sınıflandırılmıştır.



Şekil 2. ESP-2 ile belirlenmiş optimum ölçek parametresi.

Sınıflandırma ile üretilen tematik haritaların doğruluğu test için ayrılan (yer kontrol veri setinin yaklaşık % 70'i) kısmı ile gerçekleştirilmiştir. Nesne-tabanlı sınıflandırma işlemi, eCognition yazılımında bulunan ve segmentler üzerinden sınıf hiyerarşisine göre alınan örneklere dayanan en yakın komşuluk sınıflandırma algoritması ile sınıflandırılmıştır. Nesne-tabanlı sınıflandırma sonucunda genel doğruluk %78.3 ve kappa deęeri 0.75 olarak hesaplanmıştır. Piksel-tabanlı sınıflandırma işlemi ise en büyük benzerlik sınıflandırıcısı kullanılarak kontrollü sınıflandırma işlemi ile sınıflandırılmıştır. Yapılan analizler sonucunda genel sınıflandırma doğruluğu %72,2 ve kappa deęeri 0,68 olarak hesaplanmıştır. Piksel-tabanlı ve nesne-tabanlı sınıflandırma sonuçlarına ait doğruluk analizleri Çizelge 2-3'de gösterilmiştir.

Çizelge 2. Piksel-tabanlı sınıflandırma sonuçları

	Üretici Doğruluęu (%)	Kullanıcı Doğruluęu (%)
Mısır-işlenmemiş toprak	49.01	65.50
Mısır-az işlenmiş toprak	71.81	56.92
Saman	83.02	98.28
Çayır-aęaç	94.52	86.03
Çayır-otlak	99.58	100.00
Soya fasülyesi- işlenmemiş toprak	79.12	48.55
Soya fasülyesi- az işlenmiş toprak	63.89	73.70
Soya Fasülyesi	35.95	52.23
Ormanlık alan	98.81	95.49
Genel Doğruluk	72.20	
Kappa katsayısı	0.68	

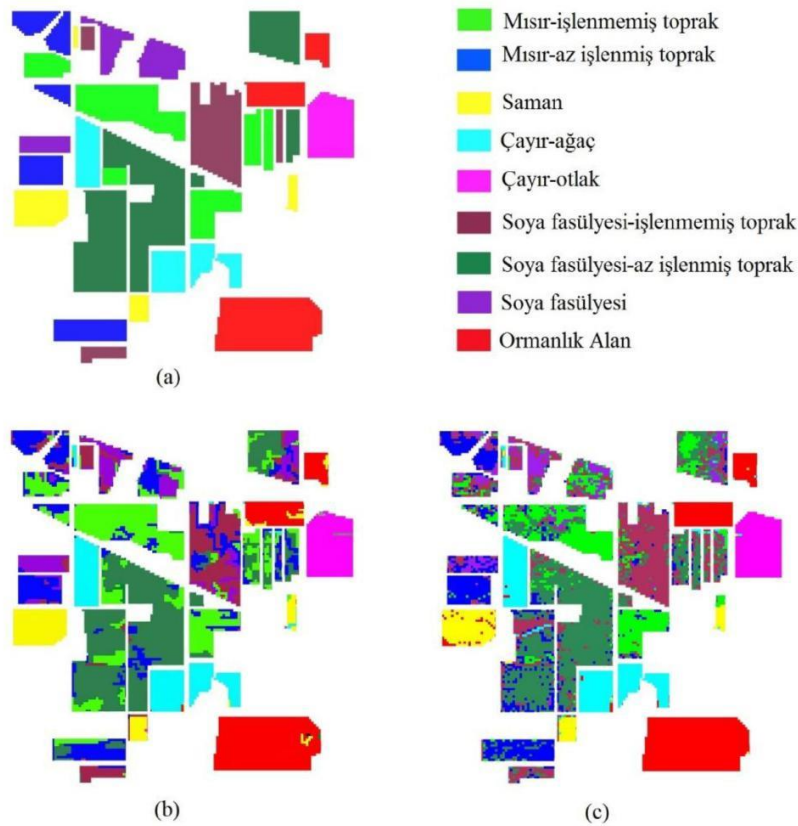
Çizelge 3. Nesne-tabanlı sınıflandırma sonuçları

	Üretici Doğruluęu (%)	Kullanıcı Doğruluęu (%)
Mısır-işlenmemiş toprak	75.18	69.27
Mısır-az işlenmiş toprak	69.16	44.84
Saman	90.01	89.51
Çayır-aęaç	98.90	96.65
Çayır-otlak	97.07	99.57
Soya fasülyesi- işlenmemiş toprak	60.49	73.41
Soya fasülyesi- az işlenmiş toprak	74.40	87.08
Soya fasülyesi	55.54	57.29
Ormanlık alan	95.81	99.75
Genel Doğruluk	78.30	
Kappa katsayısı	0.75	

Çizelge 2-3'de görüleceği üzere, nesne-tabanlı sınıflandırma sonucunda, mısır-işlenmemiş toprak sınıfının üretici

doğruluğunun %49.01 seviyesinden %75.18 seviyesine çıktığı, saman sınıfının üretici doğruluğunun %83.02 seviyesinden %90.01 seviyesine çıktığı, çayır-ağaç sınıfının üretici doğruluğunun % 94.52 seviyesinden % 98.90 seviyesine çıktığı, soya fasülyesi-az işlenmiş toprak sınıfının üretici doğruluğunun %63.89 seviyesinden %74.40 seviyesine çıktığı ve soya fasülyesi sınıfının üretici doğruluğunun %35.95 seviyesinden %55.54 seviyesine çıktığı tespit edilmiştir. Soya fasülyesi sınıfının üretici doğruluğunun nesne-tabanlı sınıflandırma ile büyük bir artış gösterdiği saptanmasına karşın düşük bir doğrulukta kaldığı ve diğer sınıflardan büyük ölçüde ayrışamadığı gözlemlenmiştir.

Kullanılan sınıflara ait yeterli sayıda eğitim veri setinin olmamasına bağlı olarak bazı sınıfların birbirinden ayrışamadığı ve karıştığı görülmüştür. Nesne-tabanlı ve piksel-tabanlı sınıflandırma işlemi ile oluşturulan tematik haritalar ve kullanılan referans veri seti Şekil 3’de gösterilmiştir. Nesne-tabanlı sınıflandırma sonucunda (Şekil 3-b), soya fasülyesi- az işlenmiş toprak, soya fasülyesi, mısır-az işlenmiş toprak, soya fasülyesi-işlenmemiş toprak ve mısır-işlenmemiş toprak sınıflarının birbirleriyle karıştığı gözlemlenmiştir. Piksel-tabanlı sınıflandırma sonucunda (Şekil 3-c), ise nesne-tabanlı-sınıflandırma sonucuna benzer olarak aynı sınıfların karıştığı ve ek olarak saman sınıfının diğer sınıflarla karıştığı gözlemlenmiştir. Ayrıca, piksel-tabanlı sınıflandırmada tuz-biber gürültü etkisinin sınıflandırma performansında negatif etki yaptığı görülmüştür. Nesne-tabanlı sınıflandırmada ise daha homojen alanların oluştuğu ve böylelikle sınıflandırma performansının arttığı gözlemlenmiştir.



Şekil 3. Sınıflandırmış görüntüler (a) Referans veri seti, (b) Nesne-tabanlı sınıflandırma sonucu, (c) Piksel-tabanlı sınıflandırma sonucu.

Söz konusu genel doğruluklar arasındaki farklılıkların istatistiksel olarak anlamlılığının analizi amacıyla McNemar’s testi uygulanmıştır. Hesaplanan istatistik değerinin (20,32), %95 güven aralığında kritik tablo değerinden (3,84) büyük olduğu tespit edilmiş, dolayısıyla söz konusu farklılıkların istatistiksel olarak anlamlı olduğu sonucuna ulaşılmıştır. Diğer bir ifadeyle nesne-tabanlı sınıflandırma performansının piksel-tabanlı sınıflandırma performansına göre daha yüksek doğruluklu olduğu teyit edilmiştir.

5.SONUÇLAR

Hiperspektral görüntülerin bant sayısının fazla olması sebebiyle yapılacak olan sınıflandırma çalışmalarında hem eğitim veri seti ihtiyacı hem de ilgisiz bantların yaratacağı bozucu etkiden dolayı görüntüdeki temel ve baskın özelliklerin belirlenmesi gerekmektedir. Ayrıca, yüksek boyutlu veriler için istatistiksel tabanlı sınıflandırıcılar kullanılması durumunda kullanılacak olan eğitim veri seti boyutu önemli bir sorun teşkil etmektedir. Bu kapsamda, boyut indirgenme yöntemleri kullanılarak, önemli bir veri kaybı olmadan görüntü indirgenmiş halinin kullanılması gerekmektedir.

Bu çalışmada boyut indirgeme yöntemlerinden olan TBA yöntemi kullanılarak Indian Pine hiperspektral görüntüsü piksel-tabanlı ve nesne-tabanlı sınıflandırma yöntemleriyle sınıflandırılmış ve tematik haritalar üretilmiştir. Veri setlerinin sınıflandırılması ve tematik harita üretiminde en büyük benzerlik ve en yakın komşuluk algoritmaları kullanılmış ve sınıflandırma performansları detaylı bir şekilde analiz edilmiştir. Çalışma sonucunda, piksel-tabanlı sınıflandırma yaklaşımı ile %72.2 genel doğruluk elde edilirken, nesne-tabanlı sınıflandırma yaklaşımı ile %78.3 genel doğruluk elde edilmiştir. Nesne-tabanlı sınıflandırma doğruluğunun, piksel-tabanlı sınıflandırma doğruluğuna göre % 6 artış gösterdiği saptanmış ve sınıflandırma doğruluğundaki bu artışın istatistiksel olarak anlamlı olduğu yapılan istatistik test ile ortaya konulmuştur. Bazı sınıfların spektral olarak benzer olduğu ve ayrımının kullanılan sınıflandırma metotlarıyla zor olduğu gözlemlenmiştir. Elde edilen sonuçlar bir arada değerlendirildiğinde nesne-tabanlı sınıflandırma işleminde spektral bilginin yanı sıra dokusal özelliklerin de kullanılmasının ve oluşturulan segment kalitesinin sınıflandırma doğruluğuna olan olumlu etkisi görülmüştür. Bu doğruluk seviyesinin rastgele orman ve destek vektör makineleri gibi veri seti dağılımından bağımsız ve sınırlı veri ile yüksek performans gösteren metotlar ile daha da yükseleceği düşünülmektedir.

KAYNAKLAR

Agarwal, A., El-Ghazawi, T., El Askary, H., Le-Moigne, J., 2007, Efficient hierarchical-pca dimension reduction for hyperspectral imagery, *Signal Processing and Information Technology IEEE International Symposium*, Cairo, pp: 353-356.

Asmala, A, Shaun, Q., 2012, Analysis of maximum likelihood classification on multispectral data. *Applied Mathematical Sciences*, 6(129), 6425–6436.

Aydogdu, A.S., Esen Yüksel, S., Özparlak L., Hatipoğlu, P. U., 2015, LWIR ve MWIR Görüntülerde Yerel Doğrusal Gömme ile Boyut Azaltma ve Anomali Tespiti, *23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Malatya, “4 syf, CDROM”.

Bajcsy, P., Groves, P., 2004. Methodology for hyperspectral band selection, *Photogrammetric Engineering and Remote Sensing*, 70, 793-802.

Blaschke, T., Lang, S., Lorup, E., Strobl, J., Zeil, P., 2000, Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications, *Environmental Information for Planning, Politics and the Public*, 2., 555–570.

Benz, U.C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004, Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information, *ISPRS Journal of Photogrammetry and Remote Sensing*, 58(3-4), 239- 258.

Datta, A., Ghosh, S., Ghosh, A., 2014, Band elimination of hyperspectral imagery using partitioned band imagecorrelation and capacity discrimination, *International Journal of Remote Sensing*, 35, 554-577.

Drăgut, L., Tiede D., Levick S. R., 2010, ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data, *International Journal of Geographical Information Science*, 24, 859-871.

Drăguț, L., Csillik, O., Eisank, C., Tiede, D., 2014, Automated parameterisation for multi-scale image segmentation on multiple layers, *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 119–127.

Hofmann, P., Strobl, J., Blaschke, T., Kux, H., 2008. Detecting informal settlements from QuickBird data in Rio de Janeiro using an object-based approach, in *Object-based image analysis concepts for knowledge driven remote sensing applications*. Springer, pp. 531-554.

Kalkan, K., 2011, Kentsel gelişim için potansiyel açık alanların belirlenmesinde nesne tabanlı sınıflandırma yöntemi ile transfer edilebilir kural dizisi oluşturulması, *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, İstanbul.

Kamal, M., Phinn, S., 2011. Hyperspectral Data for Mangrove Species Mapping: A Comparison of Pixel-Based and Object-Based Approach. *Remote Sensing*, 3(10), 2222-2242.

Kavzoglu,T., Yildiz, M., 2014, Parameter-Based Performance Analysis of Object-Based Image Analysis Using Aerial and Quikbird-2 Images, *ISPRS Annual Photogrammetry, Remote Sensing Spatial Information Sciences.*, II-7, pp: 241-247.

- Kavzoglu, T., Yildiz, M.**, 2016a, A Hierarchical Scale Setting Strategy for Improved Segmentation Performance Using Very High Resolution Images, *12th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences*, Montpellier, “7 pp, CDROM”
- Kavzoglu, T., Yildiz Erdemir, M., Tonbul, H.**, 2016b, A Region-Based Multi-Scale Approach for Object-Based Image Analysis, *ISPRS Annual Photogrammetry, Remote Sensing Spatial Information Sciences.*, VII-4, pp: 31–37.
- Kim, M., Madden, M., Warner, T.**, 2009, Forest type mapping using object-specific texture measures from multispectral Ikonos imagery: segmentation quality and image classification issues, *Photogrammetric Engineering and Remote Sensing*, 75(7), 819-829.
- Kim, M., Warner, T. A., Madden, M., Atkinson, D. S.**, 2011, Multi-scale GEOBIA with very high spatial resolution digital aerial imagery : scale , texture and image objects, *International Journal of Remote Sensing*, 32 (10), 2825-2850.
- Li, J., Huang, X., Gamba, P., Bioucas-Dias, J.M.B., Zhang, L., Benediktsson, J.A., Plaza, A.**, 2015, Multiple feature learning for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 53, 1592-1606.
- Marpu, P. R., Neubert, M., Herold, H., Niemeyer, I.**, 2010, Enhanced evaluation of image segmentation results. *Journal of Spatial Science*, 55(1), 55-68.
- Mather, P.M.**, 1999, *Computer Processing of Remotely Sensed Images*, Second Edition (Chichester: John Wiley & Sons).
- Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q.**, 2011, Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 115(5), 1145– 1161.
- Regan, D., Srivatsa, S.K.**, 2015, Dimensionality reduction of hyperspectral image using RBF-PCA and mixed pixel wise HSMM characterization using SVM-FSK for classification, *Global Journal of Pure and Applied Mathematics*, 11 (3), 1603-1626.