NESNE TABANLI VE PİKSEL TABANLI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI (IKONOS ÖRNEĞİ)

K. Kalkan[1], D. Maktav[2]
[1]İstanbul Teknik Üniversitesi, Geomatik Mühendisliği Bölümü, 34469, Maslak, İstanbul. kalkank@itu.edu.tr
[2]İstanbul Teknik Üniversitesi, Geomatik Mühendisliği Bölümü, 34469, Maslak, İstanbul. maktavd@itu.edu.tr

ÖZET

Günümüzde dijital görüntü işleme tekniklerinin gelişmesinin bir sonucu olarak, arazi örtüsünün/kullanımının uydu görüntülerinden çıkarımı için çeşitli yöntemler kullanılmaktadır. Piksel tabanlı sınıflandırma bu yöntemlerim en başta geleni olmasına rağmen son yıllarda uydu görüntülerinin mekansal çözünürlüklerinin artmasının da bir sonucu olarak nesne tabanlı sınıflandırma yöntemi de etkin olarak kullanılmaktadır.Bu çalışma kapsamında yüksek mekansal çözünürlüklü IKONOS görüntüsü kullanılarak bu iki yöntem karşılaştırılmıştır. Piksel tabanlı sınıflandırma sadece piksellerin istatistiksel analizine dayandığından, pikselleri segmentasyon aşamasında gruplandırarak bu segmentlerin renk, sıklık ve komşuluk gibi birçok özelliğini kullanan nesne tabanlı sınıflandırma yöntemi tematik sınıf için daha anlamlı ve olumlu sonuçlar vermiştir. Ayrıca nesne tabanlı sınıflandırma işlemi, kullandığı karar seti (ruleset) ya da fuzzy logic algoritmaları ile devamlı şekilde güncellenebilir bir yapıya sahiptir. En çok kullanılan nesne tabanlı görüntü analizi yazılımı olan Definiens eCognition yazılımı sahip olduğu en yakın komşuluk (nearest neighbour) sınıflandırma yöntemi ile de piksel tabanlı yaklaşıma benzer bir yaklaşım sunmakta ve aynı anlamlı sonuçları daha pratik bir şekilde vermektedir. Çalışma sırasında birçok parametre setleri, segmentasyon aşaması için değişik ölçek kriterleri, farklı segmentasyon aşamaları ve en yakın komşuluk yaklaşımı test edilmiştir. Yapılan analizler sonrasında nesne tabanlı yaklaşım birçok arazi örtüsü/kullanımı sınıfı için başarılı sonuçlar vermiştir. Doğruluk analizleri ve karşılaştırmalı sonuçlar verilmiş ve sonuçlar tartışılmıştır.

Anahtar Sözcükler: IKONOS, Definiens, Segmentasyon, Nesne Tabanlı Sınıflandırma, Piksel Tabanlı Sınıflandırma

COMPARISON OF PIXEL BASED AND OBJECT BASED CLASSIFICATION METHODS (IKONOS EXAMPLE)

ABSTRACT

Recent advances help us to determine land use and land cover from satellite imageries by using different methods. Pixel based classification is the best known method, furthermore as a result of high resolution satellite imageries object based classification system can be used effectively. Within this study, these two methods were compared by using high spatial resolution IKONOS imagery. Pixel based classification is based on statistical analysis of pixels but object oriented classification system gathers pixels while segmentation step and using different relationships of this segments like color, density and neighborliness more meaningful and better result can be obtained for many thematic classes. Also, object based classification method using fuzzy logic algorithms and rule set function, has an updateable structure. Most known object oriented image analysis software Definiens eCognition has a simple and quick "nearest neighbor" classification algorithm which obtains parallel results to pixel based method. Within this study, many parameter sets, segmentation levels with different scale factors and nearest neighbor approach have been tested. Object based classification approach gives better results for many thematic classes. Accuracy assessments and comparative results have been showed and discussed.

Keywords: IKONOS, Definiens, Segmentation, Object based classification, Pixel based classification.

1. GİRİŞ

Uydu teknolojilerindeki gelişimin son yıllarda hızlanması ile birlikte uzaktan algılama teknolojilerinde önemli bir gelişim olmuştur. Özellikle son yıllarda yüksek çözünürlükte mekansal ve spektral bilgi üreten ve bu bilgiyi topluma sunan yüksek çözünürlüklü uyduların gelişmesi mekânsal bilgi üretiminde çok büyük kolaylık sağlamaktadır. Uydu görüntülerinin fiyatlarının düşmesi ve topluma sunulması da birçok uygulamanın yapılmasını kolaylaştırmıştır.

Uydu görüntüleri ormancılıktan jeodeziye, meteorolojiden askeri uygulamalara kadar birçok alanda kullanılmaktadır. Uydu görüntülerinin insan gözünün algılayamadığı bitki hastalıkları, klorofil miktarı, su kalitesi ve su kirliliği gibi özellikleri ayırt edebilmesi birçok kolaylığı ve analiz kolaylığını da beraberinde getirmiştir.

Sınıflandırma görüntü yorumlama teknikleri kullanılarak görüntüdeki homojen piksel gruplarının ilgilenilen yeryüzü özelliklerine ve yeryüzü kullanım özelliklerine ayrılması şeklinde tanımlanabilir (Chandra ve Ghosh, 2007). Dijital görüntü sınıflandırmada ise, kullanıcı görüntüdeki dijital sayılarla gösterilen spektral bilgiyi kullanarak çeşitli bantlar üzerinde spektral özelliklere göre pikselleri sınıflandırır. Bu tip sınıflandırmaya spektral doku tanımlama da denebilir. Burada amaç görüntüdeki tüm pikselleri çeşitli sınıflara ya da temalara atamaktır. Sınıflandırma sonucunda oluşan haritada her piksel kendine mahsus bir özelliğe atanmış bir şekilde orijinal görüntünün tematik haritası elde edilmiş olur.

Sınıflar hakkında söz ederken "bilgi sınıfları" ve "spektral sınıflar" terimlerini birbirinden ayırmak gerekir. Değişik tarla türleri, orman türleri, kaya türleri gibi kullanıcının görüntü üzerinde ayırmaya çalıştığı değişik ilgi kategorilerine bilgi sınıfları denir. Spektral sınıflar ise, aynı yansıtım değerlerine sahip piksellerin bir arada bulunduğu sınıflardır. Sınıflandırmada temel amaç spektral sınıflar ile bilgi sınıflarını eşleştirmektir. Burada herhangi birkaç spektral sınıf aynı bilgi sınıfını temsil edebilir, ya da bazı spektral sınıflar herhangi bir bilgi sınıfının özelliğini göstermeyebilir, bu noktada sınıflandırmayı yapan kişi hangi sınıfın hangi bilgi sınıfına ait olduğuna karar vermesi gerekir (James, 2002).

Sınıflandırma işlemi uzaktan algılama uygulamalarında temel uygulamalardan biridir. Bu çalışmada hem piksel tabanlı hem de nesne tabanlı sınıflandırma işlemleri uygulanarak sonuçları, faydaları ve dezavantajları karşılaştırılmıştır. Piksel tabanlı sınıflandırma için ERDAS Imagine yazılımı, nesne tabanlı sınıflandırma için ise eCognition yazılımı kullanılmıştır. Her iki yazılımdaki sınıflandırma işlem akışı ve sonuçlar çalışma kapsamında açıklanmıştır.

2. VERİ VE YÖNTEM

Çalışma alanı olarak seçtiğimiz Çakıllı köyü, Kırklareli ilinin Vize ilçesine bağlı bir beldedir (Şekil 1). Çalışma kapsamında 22.05.2006 tarihli çok spektrumlu (multispectral) IKONOS görüntüsü kullanılmıştır. eCognition yazılımında işlem adımlarının yavaşlamaması için 2km*2km bir AOI (Area of Interest) seçilerek çalışmalar bu görüntü üzerinden yapılmıştır.

Yazılım olarak ise piksel tabanlı sınıflandırma için ERDAS Imagine 9.1 ve nesne tabanlı sınıflandırma için eCognition Professional 4.0 kullanılmıştır. Çalışma kapsamında kullanılan sınıflandırma yöntemleri ve iş akış diyagramı Şekil 2'de görülmektedir.

Şekil 1. Uygulama alanının Türkiye coğrafyası üzerindeki yeri

Tablo 1'de her iki yazılımın da sahip olduğu sınıflandırma yöntemleri görülmektedir. Ayrıca birbiri ile entegre bir yapıda çalışması açısından ERDAS ve eCognition yazılımlarındaki işlem akışlarının karşılaştırılması da Şekil 3'de gösterilmiştir.

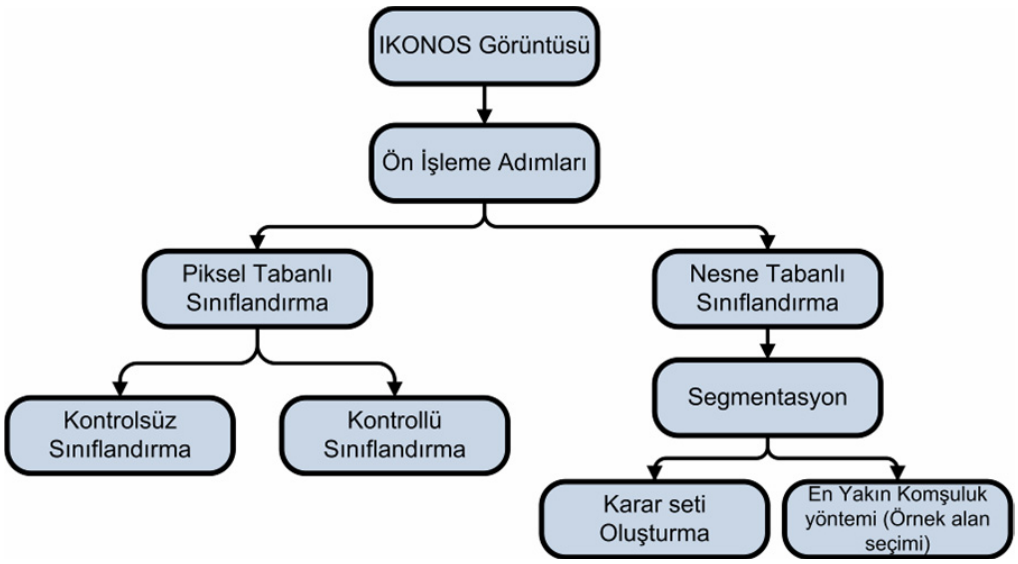

Şekil 2. Kullanılan sınıflandırma yöntemleri ve iş akış diyagramı

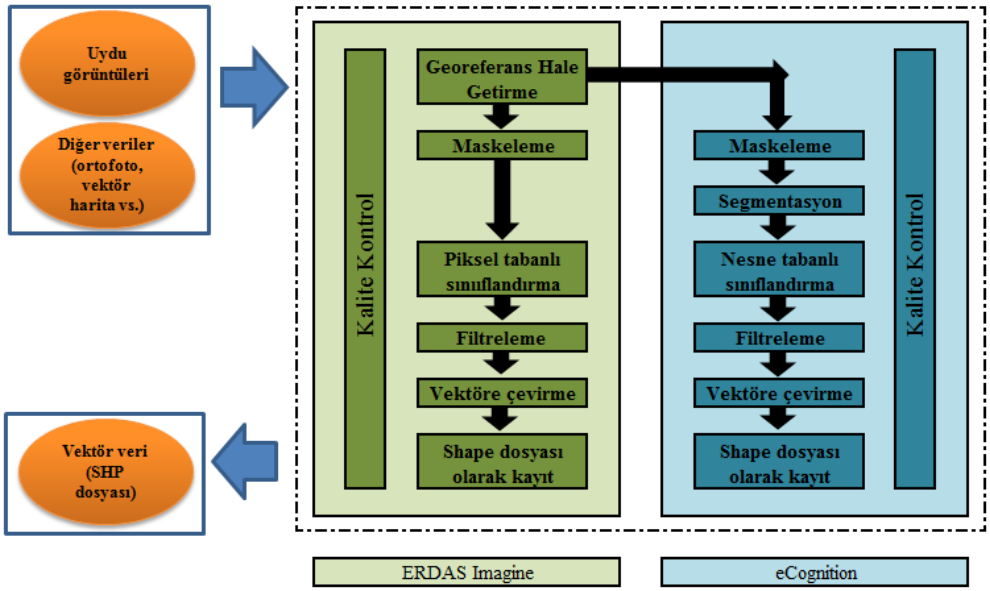

Şekil 3. ERDAS ve eCognition yazılımlarındaki iş akış diyagramı ve birlikte çalışabilirlik (Ohlhof, 2006)

Tablo 1. ERDAS yazılımı ve eCognition yazılımındaki sınıflandırma yöntemleri

ERDAS Imagine	eCognition / Definiens
Kontrolsuz sınıflandırma (ISODATA yontemi)	----------
Kontrollu sınıflandırma (Örn. Maksimum Benzerlik)	----------
Knowledge-Based sınıflandırma (Expert Classifier)	----------
----------	Segmentasyon
----------	Nesne tabanlı sınıflandırma (Ruleset tanımlama)
----------	En yakın komşuluk (Örnek Seçimi) Nearest Neighbour (Sample Selection)

3. PİKSEL TABANLI SINIFLANDIRMA

Test alanına ait görüntünün ERDAS Imagine yazılımı ile sınıflandırılması için IKONOS çok spektrumlu görüntüsünde 4(R)-3(G)-2(B) band kombinasyonu kullanılmıştır. Yakın kızılötesi bandın kullanımı bitki örtüsü ve su yapılarının ayırt edilmesinde avantajlar sağlamaktadır. Çalışma alanındaki arazi örtüsünün genel olarak belirlenmesi amacıyla optimum olarak arazi örtüsünü temsil eden 15 sınıf ile kontrolsüz sınıflandırma işlemi gerçekleştirilmiştir.

Daha sonra gruplanan 15 tematik sınıf baz alınarak, yer gerçeğinin belirlenmesinde yardımcı olan ortofotolar ve Google Earth gibi yazılımlar eşliğinde en büyük benzerlik (Maximum Likelihood) algoritması ile kontrollü sınıflandırma işlemi gerçekleştirilmiştir. Mevcut arazi kullanımını yansıtacağı düşünülen 8 tematik sınıf için 156 adet örnekleme alanı seçilmiştir. Bu örnekleme sırasında tüm görüntü üzerine yayılmış homojen ve ortak yeryüzü örtü tipi türüne sahip bölgeler seçilmeli ve sonrasında oluşan RGB değerleri kontrol edilmelidir. Şüphesiz ki örnekleme kontrollü sınıflandırmanın en önemli kısmıdır ve örnekler arasındaki tutarlılık sınıflandırmanın sonucunu birebir etkilemektedir. Bu kısımda yapılan arazi çalışmalarının önemi boy göstermektedir.

4. NESNE TABANLI SINIFLANDIRMA

Uygulama için seçilen test bölgesine ait uydu görüntüsünün piksel tabanlı sınıflandırmasının yapılmasından sonra eCognition yazılımı ile nesne tabanlı sınıflandırma işlemine geçilmiştir. Nesne tabanlı sınıflandırma için test alanına ait 4 bantlı çok spektrumlu IKONOS görüntüsünün tüm bantları kullanılmıştır.

Nesne tabanlı sınıflandırmanın en önemli bölümü olan segmentasyon aşamasında doğru ölçekte yapılan çok ölçekli analizler baskın nesneler arasındaki baskın sınırların belirlenmesi açısından önemlidir (Hall et al., 2004). Segmentasyon aşamasında birbirine benzer yansıtım özelliklerine sahip pikseller gruplandırılır ve böylece milyonlarca piksel ile çalışmak yerine bu ortak özelliklere sahip pikseller birleşerek segmentler oluşur ve bu aşamada segmentlerin kendileri arasındaki heterojenlik en düşük seviyeye indirilmiş olur. Kullanıcı bu aşamada spektral homojenliğin ya da heterojenliğin önemine göre istediği spektral katmanları kullanarak çeşitli ölçek faktörlerinde segmentasyon katmanları oluşturur (Benz at al., 2004). Ayrıca, oluşan segmentlerin yansıtım özellikleri yanında doku, uzunluk ve alan gibi özellikleri de kullanılarak sınıflandırma sırasında birçok özelliğin elde edilmesi kolaylaştırılır.

Burada yapılan birçok deneme sonrasında sınıflandırma için ölçek faktörü olarak "20" seçilmesi uygun görülmüştür. Bu ölçek faktöründe hem yol ve binalar ayrılabilmekte, hem de daha büyük yapıdaki tarla segmentleri arazide büyük alanlar kaplamadığından sağlıklı olarak çıkarılabilmektedir. Shape factor olarak 0,5 değeri seçilerek hem spektral hem de şekilsel özelliklerin ortak kullanılması sağlanmıştır. Ayrıca compactness değeri 0,5 seçilerek nesnelerin daha yoğun elde edilmesi amaçlamıştır. Kullanıcı oluşturduğu segmentasyon katmanları ile değişik parametreler kullanarak nesne çıkarımları için en uygun parametreleri analiz edebilir ve her sınıf için kendine özgü bir bulanık mantık fonksiyonu geliştirebilir (Lewinski, 2004). Bu aşamada sınıflandırmada kullanılacak sınıf hiyerarşisi, piksel tabanlı sınıflandırmaya paralel olarak 8 adet sınıf halinde (ağaçlık, bina, çayırlık, su, ekili Tarla, hasatlı Tarla, toprak, yol) oluşturulmuştur.

eCognition yazılımında genel olarak 2 tür sınıflandırma yöntemi mevcuttur. Bunlardan birincisi oluşan segmentler üzerinden sınıf hiyerarşine göre alınan örneklere dayanan en yakın komşuluk (nearest neighbour) sınıflandırma algoritmasıdır. Bu yöntem temelinde kontrollü sınıflandırma algoritmasına benzemektedir, piksel tabanlı sınıflandırmada alınan örnekleme alanları gibi, nesne tabanlı sınıflandırmada da örnek segmentler seçilir. Sınıflandırmada birim olarak pikseller yerine segmentlerin kullanılması en yakın komşuluk algoritmasında işlemlerin daha hızlı biçimde ilerlemesini sağlar (Jensen, 2005). Bu işlem nesne tabanlı yöntemde daha hızlı ve daha doğru bir şekilde yapılmaktadır. Böylece her sınıf içilen seçilen örneklerin ortalama değerleri kullanılarak eCognition yazılımı en yakın komşuluk yöntemiyle tüm görüntü üzerinde ortak özelliklere sahip segmentleri bularak sınıflandırma işlemini tamamlar.

eCognition yazılımında ikinci sınıflandırma yöntemi ise tematik sınıflar için o sınıflara ait özelliklerin ve eşik değerlerinin bu sınıflar için oluşturularak bir karar seti dosyasının oluşturulması şeklindeki yöntemdir. Bu yöntemde her sınıf için hangi segmentasyon aşamasında sınıflandırmanın

yapılacağı, hangi banttaki hangi aralığın bu sınıfa atanacağı, hangi alansal ve dokusal özelliklerin sorgulanacağı gibi birçok özellik bu tematik sınıfların içine girilebilir. Böylece oluşan segmentler ek bilgilerle desteklenerek görüntü üzerinden bilgi çıkarımı yapılabilmektedir, ayrıca her aşamada parametreler güncellenerek ve eklenerek hem esnek bir yapı, hem de güncellenebilir bir karar seti oluşturulmuş olur. Şekil 4'te eCognition yazılımının içerdiği özellik tanımlamalarından bazıları görülmektedir, bu tip özellik ayrımları kullanılarak nesnelerin çıkarımı eşik değerleri ile yapılmaktadır. Bu noktada eCognition hem spektral yansıtımlar hem de nesnelerin alan, çizgisellik, uzunluk ve komşuluk gibi değişik özelliklerinden de yararlamaktadır. Ayrıca kullanıcı kendi tanımladığı algoritmaları kullanarak da segmentlerin özellikleri hakkında bilgi çıkarımı yapabilmektedir.

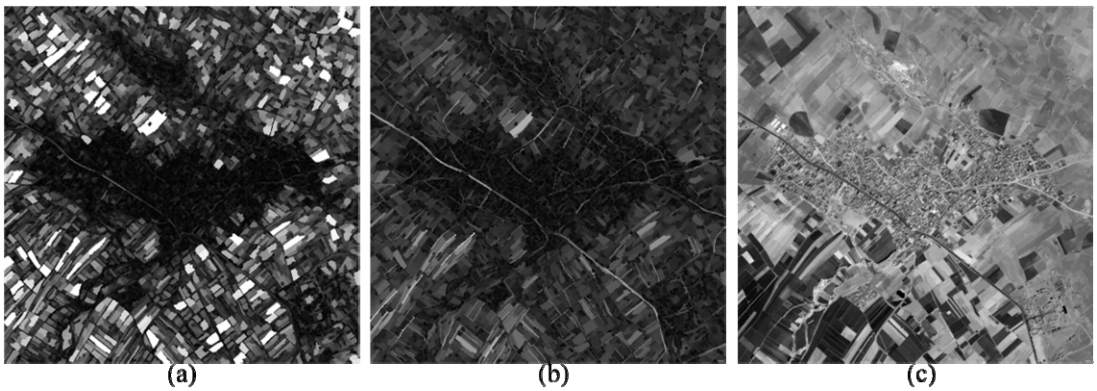

(a) (b) (c)

Şekil 4. a) Alan özelliklerine göre segmentler b) uzunluk özelliklerine göre segmentler c) yakın kızılötesi bant özelliklerine göre segmentler

Kullanılan özelliklere örnek olarak su sınıfı için yakın kızılötesi banttaki yansıtım değerleri kullanılmıştır. Yakın kızılötesi bandda 0 - 400 değerleri arasında kalan tüm segmentler su sınıfına atanmıştır. Su yapısının, yakın kızılötesi banddaki diğer arazi örtülerinden ayırımı Şekil 5b'da görülmektedir.

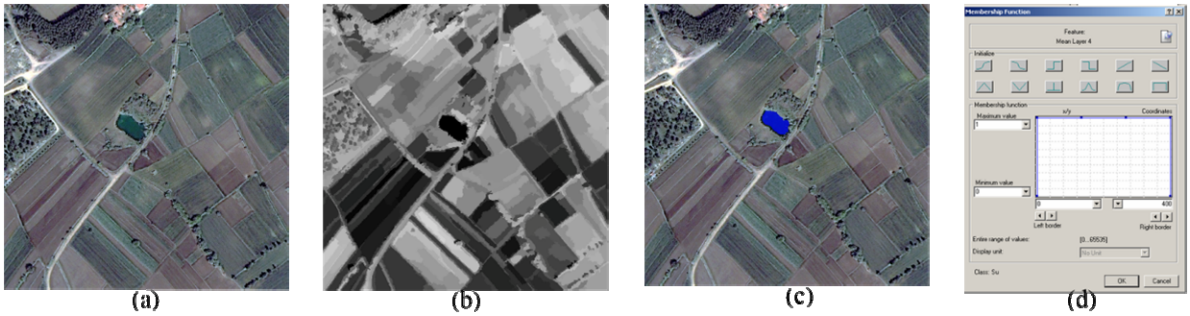

(a) (b) (c) (d)

Şekil 5. Su ayırt edilmesi için örnek alan; a) orijinal görüntü b) 4. bant ortalama değerler için özellik görüntüsü c) sınıflandırılmış görüntü d) su sınıfı için eşik değerlerinin yazılıma girilmesi

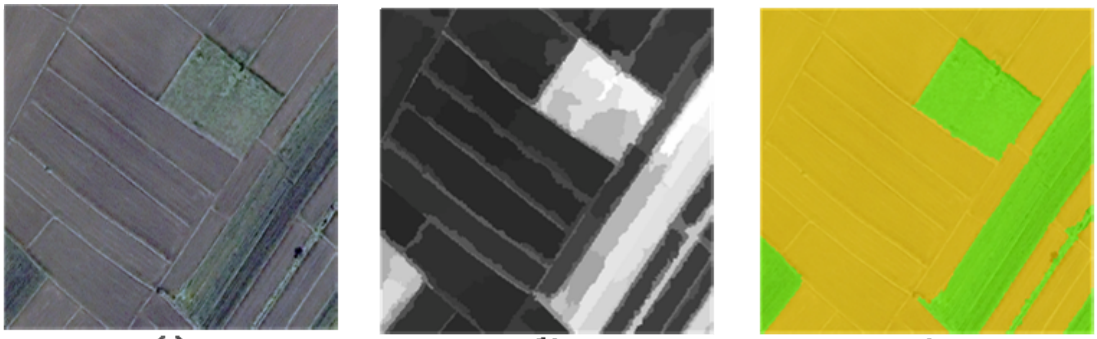

(a) (b) (c)

Şekil 6. Tarla ayrıt edilmesi için örnek alan; a) orijinal görüntü b) DDVI özellik görüntüsü c) sınıflandırılmış görüntü

Bir diğer örnek olarak tarlaların ayırt edilmesinde ise DDVI (Difference Difference Vegetation Index) (Şekil 6b) formülü kullanılmıştır. DDVI: [(2*NIR – Red) – (Green – Blue)] formülü ile tanımlanmaktadır (Eisfelder, 2009). eCognition sahip olduğu üyelik fonksiyonları oluşturma özelliği ile esnek bir yapıyla birçok formülün uygulanmasına izin vermektedir. Şekil 6b'de ekinli ve hasatlı tarlaların DDVI ile ayırımı görülmektedir. eCognition yazılımına bu sınıfların eşik değerlerinin girilmesi ile oluşan sınıflandırma sonucu Şekil 6c'de görülmektedir.

5. SINIFLANDIRMA SONUÇLARININ KARŞILAŞTIRILMASI

Her iki yazılım ile elde edilen sınıflandırma sonuçları ve orijinal görüntü Şekil 7'da görülmektedir. Uzaktan algılama görüntülerinin sınıflandırma doğruluğu, seçilen referans bilgiler ve sınıflandırılmış veri arasındaki uyuşmanın ne kadar doğruluklu olduğunun belirlenmesi anlamına gelmektedir. Piksel tabanlı sınıflandırma sonuçları için görüntü üzerinde rastgele seçilen noktalar ile yer gerçeği verilerinin uyuşumu test edilmiştir. Nesne tabanlı sınıflandırma sonuçlar için ise Definiens yazılımının içerdiği doğruluk analizi yöntemlerinden "Error Matrix based on TTA Mask" yöntemi kullanılmıştır. Bu yöntemde her bir tematik sınıf için seçilen örnek segmentler ile görüntüdeki sınıflandırılmış segmentlerin uyumu test edilir. Her iki sınıflandırma yöntemi için elde edilen doğruluk analizi sonuçları Tablo 2'de verilmiştir. Nesne tabanlı sınıflandırma yönteminde daha yüksek doğruluk elde edilmesinin yanında test alanı küçük ölçekte bir alan olduğundan, her iki yöntemde yüksek doğruluk elde edilmiştir.

Tablo 2. Nesne tabanlı ve piksel tabanlı sınıflandırma doğruluk analizleri

	ERDAS			eCognition		
Sınıf Adı	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Kappa	Üretici Doğruluğu (%)	Kullanıcı Doğruluğu (%)	Kappa
Ekili Tarla	90.48	95.00	0.9413	99.38	98.57	0.9908
Ağaçlık	90.00	90.00	0.8835	73.39	100.00	0.727
Çayırlık	82.61	95.00	0.9403	99.6	92.49	0.9956
Toprak	95.00	95.00	0.9417	99.2	99.52	0.9913
Su	100.00	100.00	1.000	100.00	100.00	1.00
Hasatlı Tarla	100.00	95.00	0.9422	100.00	99.19	1.00
Asfalt Yol	100.00	86.67	0.8531	96.24	100.00	0.9598
Yerleşim	94.74	90.00	0.8844	95.7	98.18	0.9555

Genel Sınıflandırma Doğruluğu = 92.91% Genel Kappa = 0.9181	Genel Sınıflandırma Doğruluğu = 98.39% Genel Kappa = 0.9783

Bölgede yolların büyük kısmı toprak yollardan oluştuğundan toprak yol ile yol sınıfını ayırt etmek çok güç olmuş ve bu sınıflar birleştirilmiştir. Ayrıca piksel tabanlı sınıflandırma da çayırlık ve toprak piksellerinin birbirinden ayırt edilmesi sırasında da zorlanılmıştır. Çatısı olmayan binalar nedeniyle birçok yerde toprak pikselleri ile yerleşim pikselleri karışmıştır. Ayrıca şehir gelişiminin yoğun olduğu yerlerde sıklıkla görülen karışık pikseller de (mixed-pixel) heterojenliğe neden olmaktadır (Lo ve Choi, 2004). Genel anlamda iki sınıflandırmanın da doğruluk analizleri yakın sonuçlar vermiş ise de fakat nesne-tabanlı sınıflandırma yönteminde daha iyi sonuçlar elde edilmiştir.

6. SONUÇ

Yapılan çalışma kapsamında nesne tabanlı ve piksel tabanlı sınıflandırma sistemleri karşılaştırılmıştır. Çok bantlı ve düşük mekansal çözünürlükte iyi sonuçlar veren piksel tabanlı sınıflandırmanın yanında kullanılan yüksek çözünürlüklü görüntü ile nesne tabanlı sınıflandırma da iyi sonuçlar elde edilmiştir. Kullanılan IKONOS görüntüsünün 4 bantlı bir görüntü olması piksel tabanlı sınıflandırma da bazı handikaplara yol açsada nesne tabanlı sınıflandırma sırasında oluşturulan segmentler sayesinde daha iyi sonuçlar elde edilmiştir. Yol, yerleşim gibi homojen arazi örtülerinde nesne tabanlı sınıflandırma kullandığı uzunluk, alan, lineerlik gibi özelliklerle bu sınıfların ayırt edilmesinde iyi sonuçlar vermiştir.

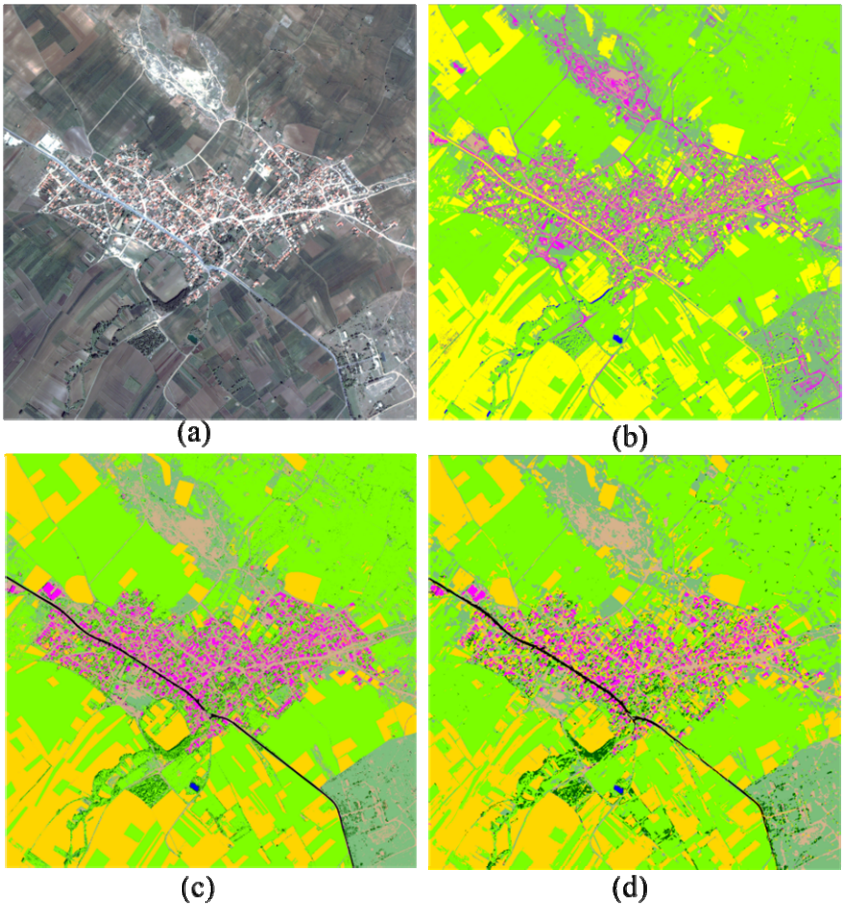

Şekil 7. IKONOS görüntüsü (Çakıllı) a) orijinal b) kontrolsüz sınıflandırlmış c) kontrollü sınıflandırlmış d) nesne tabanlı sınıflandırılmış

Nesne tabanlı sınıflandırma yazılımı olan eCognition Definiens ile yapılan sınıflandırma süreci daha hızlı ve güncellenebilir bir şekilde gerçekleşmektedir. Ayrıca yapılan yanlışlar ya da yanlış sınıf atamaları hızlı bir şekilde düzeltilebilir, sınıflandırma sonucu vektör formata çevirilerek coğrafi bilgi sistemleri ile entegre edilebilir. Pikseller yerine oluşan segmentler ile çalışmak tematik sınıflar için bilgi çıkarımında daha fazla bilgi sağlar fakat bu bilginin nasıl etkili bir şekilde kullanılacağı sorusunu gündeme getirir (Mallinis et al., 2008). Yüksek çözünürlüklü uydu görüntüleri ile yapılan nesne tabanlı sınıflandırma ile başarılı sonuçlar elde edilmiştir. Yüksek mekansal çözünürlük ve yüksek spektral çözünürlüğe sahip görüntüler için arazi kullanımının belirlenmesinde nesne tabanlı yaklaşım hızlı ve yüksek doğruluklu sonuçlar vermektedir. eCognition yazılımının diğer uzaktan algılama verileri (LIDAR vb) ile entegre bir şekilde çalışması ile daha verimli sonuçlar elde ebilebilir.

KAYNAKLAR

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.

Chandra, A.M., Ghosh S.K., 2007. Remote *Sensing and Geographical Information System*, Alpha Science International, Oxford U.K.

Eisfelder, C. , Kraus, T. , Bock, M. , Werner, M. , Buchroithner, M. F. and Strunz, G. 2009. 'Towards automated forest-type mapping - a service within GSE Forest Monitoring based on SPOT-5 and IKONOS data', *International Journal of Remote Sensing,* 30(19), 5015-5038

Hall, O., Hay, G.J., Bouchard, A., Marceau, D.J., 2004. Detecting dominant landscape objects through multiple scales: an integration of object-specific methods and watershed segmentation. *Landscape Ecology* 19(1), 59–76.

James, B.C., 2002. *Introduction to Remte Sensing.* Taylor&Francis, London. 321-322.

Jensen, J.R., 2005. Introductory Digital Image Processing: A Remote Sensing Perspective, Third ed. Prentice-Hall, New York.

Lewinski, S., Zaremski, K.., 2004. Examples of object-oriented classification performed on high-resolution satellite images, *Miscellanea Geographica*, 11.

Lo, C. P., J. Choi. 2004. A hybrid approach to urban land use/cover mapping using Landsat 7 Enhanced Thematic Mapper Plus (ETM +) images. *International Journal of Remote Sensing*, 25(14): 2687–2700.

Mallinis, G., Koutsias, N., Tsakiri-Strati, M., Karteris, M., 2008. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. *ISPRS Journal of Photogrammetry and Remote Sensing,* 63, 237-250

Ohlhof, T., 2006. Comparison study between eCognition and ERDAS Imagine for the classifitcation of high and moderate resolution satellite imagery. *4th ESA-EUSC Conference on Image Information Mining for Security and Intelligence.* Madrid, Spain.