KENTSEL GELİŞİM İÇİN POTANSİYEL ALANLARIN UZAKTAN ALGILAMA VE CBS İLE BELİRLENMESİ VE DEĞERLEMESİ

D. Maktav[1], A. Siegmund[2], C. Jürgens[3], S. Naumann[2], F. Sunar[1], H. Eşbah[4], T.B. Levent[5], İ. Akar[6], C. Uysal[1], K. Kalkan[1], Y.O. Mercan[7], N. Wolf[3], H. Thunig[2]

[1]İstanbul Teknik Üniversitesi, Geomatik Mühendisliği Bölümü, 34469, Maslak, İstanbul
maktavd@itu.edu.tr, fsunar@itu.edu.tr, uysalc@itu.edu.tr, kalkaan@gmail.com
[2] University of Education Heidelberg, Department of Geography, 69120, Heidelberg, Germany
siegmund@ph-heidelberg.de, naumann@ph-heidelberg.de, thunig@ph-heildelberg.de
[3]Ruhr–University Bochum, Department of Geography, 44780, Bochum, Germany carsten.jurgens@rub.de, nils.wolf@rub.de
[4]İstanbul Teknik Üniversitesi, Peyzaj Mimarlığı Bölümü, Taşkışla, İstanbul hayriyeesbah@yahoo.com
[5]İstanbul Teknik Üniversitesi, Şehir ve Bölge Planlaması Bölümü, Taşkışla, İstanbul tuzin.baycanlevent@itu.edu.tr
[6]Marmara Üniversitesi, Ortadoğu Araştırmaları Enstitüsü, Ortadoğu Coğrafyası Anabilim Dalı, İstanbul irfanakar@gmail.com
[7]İstanbul Teknik Üniversitesi, Bilişim Enstitüsü, Hesaplamalı Bilim ve Mühendislik Bölümü, Maslak, İstanbul onatmercan@gmail.com

ÖZET

Küreselleşmeye paralel olarak kentsel alanlar da hızla büyümektedir. Nitekim 1970'li yılların sonlarında nüfusun sadece %38'i kentlerde otururken, bu sayı 2008 yılına kadar %50'nin üzerinde artmıştır. 2030'da dünyadaki tüm nüfusun 2/3'ünün kentlerde ve bunların çoğunun da megakentlerde oturacağı beklenmektedir. Kentsel yayılım (urban sprawl), farklı karakteristiklerde ve kıtalarda bu kentleri ve kentsel yerleşim alanlarını etkileyen önemli bir çevre sorunudur. Son 10-30 yıldaki kentsel yayılımdaki artışla ilgili olarak çeşitli nedenler ortaya atılmakta olup, bu artış ekseriya kentlerin sosyo ekonomik durumuna bağlanmaktadır. Kent planlamasında taşınmaz tüketiminin kantitatif azaltılması dışında, sınırlı kaynakların ve akıllı büyümenin (smart growth) sürdürülebilir biçimde ele alınması ve buna yönelik hassas ve uygulanabilir enstrümanların geliştirilmesi gerekmektedir. Yüksek mekânsal (IKONOS, QUICKBIRD, GeoEye-1 gibi) ve spektral çözünürlüklü uydu görüntüleri kent çevresinin analizinde uygun bir bilgi kaynağı olduğundan bu kaynaklardan yararlanılan bir planlama enstrümanının geliştirilmesi gerekir. Bu kapsamda, Berlin ve İstanbul'u örnek olarak alan bir proje başlatılmıştır. İlk adımda, her iki kentteki az gelişmiş kentsel alanlar saptanacaktır. İkinci adımda ise, saptanan bu alanlar, kentsel konsolidasyon potansiyellerine göre, bir "çok kriterli karar destek sistemi" ile değerlendirilecektir. Tanımlanacak kurallar, her iki kent için ek mevcut verileri (örneğin alt yapı gibi) içermektedir. Geliştirilecek olan planlama enstrümanı, üçüncü bir bölgeye (Ruhr Bölgesi, Almanya) uygulanarak test edilecektir. Çalışmanın amacı, seçilen bilimsel teknolojilerin sağlayacağı avantajları, bu teknolojilerin henüz geniş kapsamlı kullanılmadığı şehir ve bölge planlamaya taşımaktır. Geliştirilecek araçta, yerleşim alanları paternlerinin zamansal ve mekânsal değişimlerinin zamanında tanımlanmasına, ölçülmesine ve modellenmesine yardımcı olan güncel uzaktan algılama verileri ve coğrafi bilgi sistemleri (CBS) analizleri kullanılacaktır. Bu araç, aynı zamanda bölgesel gereksinimlere ve amaçlara uyarlanabilir bir sistem de sağlamalıdır. Bunun sonucu olarak, önerilen araştırma ve planlama aracı, bölge yetkililerinin planlama kararlarında destek sağlayabilmeli ve kentsel yayılım süreciyle mücadelede yardımcı olabilmelidir. Bu nedenle, proje çıktıları, planlama yetkililerine ve ağ oluşturulmasına yaygınlaştırılacak ve proje ortakları arasında bilgi transferi ve farklı bölgesel deneyimleri nedeniyle deneyim alışverişi sağlanacaktır.

Anahtar Sözcükler: Akıllı Büyüme, QuickBird, Nesne Tabanlı Sınıflandırma, Çok Kriterli Karar Verme.

DETECTION AND VALUATION OF POTENTIAL AREAS FOR URBAN DEVELOPMENT WITH REMOTE SENSING AND GIS

ABSTRACT

One of the major accompaniments of the globalisation is the rapid growing of urban areas. Wheras at the end of the 1970th only 38% of people lived in cities, this number increased until 2008 to more than 50%. In 2030 two third of all people worldwide are expected to live in cities, many of them in megacities (http://www.emerging-megacities.org). Urban sprawl is a major environmental concern affecting these cities and urban regions across differing characteristics and continents. Various reasons for the increase in urban sprawl in the last 10 to 30 years have been proposed, and often depend on the socio-economic situation of the cities. Besides a quantitative reduction of land consumption, sustainable handling of the limited resource land and "smart growth" are acknowledged as key tasks for urban planning. Coping with these tasks requires precise and adaptive planning instruments. High spatial and spectral resolution satellite images seem to be a suitable source of reliable information about multiple facets of the urban environment. Consequently, a planning instrument utilizing these sources should be developed. In this context a case study approach taking the examples of Berlin and Istanbul is considered suitable. In a first step, underdeveloped urban areas will be detected in both cities. In a second step, the detected areas will be valuated regarding their potential for urban consolidation, using amulti-criteria decision support system. The rules to be defined include additional available data for the two cities, for instance infrastructure. The developed planning instrument will be evaluated by applying it to a third region (Ruhr region, Germany). The objective of the project is to transfer the advantages of selected scientific technologies to

city and regional planning, in which they are not yet widely used. The tool to be developed uses up-to-date remote sensing data and GIS analyses which help to describe, measure and model temporal and spatial variations of settlement patterns in a timely manner. The tool also provides a system adaptive to local needs and objectives. Consequently, it can be assumed that the proposed research and planning tool can support local authorities in planning decisions and help to combat the urban sprawl process. Therefore the dissemination of the results of the project to planning authorities and network building will be one of the outcomes as well as the knowledge transfer and exchange of experiences between the project partners due to their different regional expertise.

Keywords: Smart Growth, QuickBird, Object Oriented Classification, Multi Criteria Decision Analysis.

1. GİRİŞ

Günümüzde, kentlerin, denetimsiz büyümenin getirdiği sorunlara ve bu çerçevede bireylerin ve toplumun gereksinmelerine nasıl yanıt vereceği konusu, en temel sorulardan birini oluşturmaktadır. Bugün dünya nüfusunun yarısının kentlerde yaşadığı düşünülürse, bu sorunun doğru yanıtlarının arandığı bir kent planlama sisteminin önemi daha da artmaktadır. İnsanların çevre bilincinin geçmiş yüzyıllara oranla arttığı günümüzde daha kontrollü, akıllı, sürdürülebilir olması gereken geleceğin kentlerini planlamak hedefi yeni çözümler üretilmesine neden olmuştur. Klasik piksel tabanlı sınıflandırma yöntemlerinde, sadece piksellerin gri değerine dayalı detay çıkarımı esastır. Bu durum, görüntüden ancak belirli özelliklerin çıkartılabilmesi nedeniyle sınıflandırmada bazı sınırlamalara neden olmaktadır. Buna alternatif olarak günümüzde nesne tabanlı görüntü analizi uygulanmaktadır. Bu, spektral değer, şekil ve doku gibi değişik nesne özelliklerinin geniş spektrumunun tamamlanmasını sağlayan bulanık mantık esasına dayanmaktadır. Sözü edilen klasik yöntemlerin yapısından kaynaklanan yetersizliklerden dolayı, nesne tabanlı görüntü analizi günümüzde daha çok kullanılmaya başlanmıştır. Nesne tabanlı yaklaşım, yapıyı, dokuyu ve spektral bilgiyi dikkate almaktadır. Piksel tabanlı sınıflandırma mantığından farklı olarak nesne tabanlı sınıflandırma, pikselleri gruplandırarak nesneler üzerinde işlemler yapmaktadır. Bu tür segmentasyon ve topoloji oluşumu, çözünürlüğe ve çıkarılması düşünülen nesnelerin ölçeğine göre belirlenmelidir. Bu yöntemle, sadece tekil pikseller sınıflandırılmamakta, ayrıca bir önceki segmentasyon basamağı sırasında homojen görüntü nesneleri de ortaya çıkarılmaktadır (Hofmann, 2001a,b). Segmentasyon işlemi değişik çözünürlüklerde yapılabilirken, nesne kategorilerinin katmanlarını ayırt etmeye de izin vermektedir.

Çalışmanın çok kriterli analizler kısmında, CBS ortamında uygunluk ve çok kriterli analizlerle ekolojik ve mevcut alan kullanımlarının yakınlık kriterlerinin bir arada kullanılması ile en uygun alan kullanım atamasının yapılmasını sağlayan bir modelin geliştirilmesi hedeflenmektedir. Çalışmada odaklanılan alan kullanımları; açık ve doğal alanlar, konut alanları, endüstriyel alanlar ve tarım alanları olarak 4 ana kategoride ele alınmıştır. Burada mevcut alan kullanımlarına, uzaklık kriterine hali hazırdaki kullanımların akıllı gelişmede belirleyici rol oynamasından dolayı yer verilmiştir. Bu sınıflandırma oldukça genel olmasına rağmen daha detaylı kategorileri içeren bir çalışma yönetimsel, kültürel ve sosyo-ekonomik kriterler kullanılarak ileriki yıllarda planlanabilir. Çalışmanın çok kriterli analizlerle ilgili işlemlerine başlamadan önce kısıtlamaların olduğu alanların belirlenmesi ve bu alanların maskelenmesi gerekmektedir. Böylece mülkiyet durumu kamuya ait olan yerler, koruma alanları, askeri bölgeler, hava alanları gibi ulaşım birimleri çalışmanın ileriki aşamalarına dahil edilmeyecektir. Bunu takip eden aşamada çalışma analitik olarak 3 ana adımdan oluşmaktadır: 1- CBS veri tabanının oluşturulması, 2- Ekolojik ve çevresel kriterlerin ölçütlerinin belirlenmesi ve ağırlıklandırılması (MCE) ve bunların CBS'de işlenmesi ile her bir alan kullanımı için ayrı ayrı uygunluk haritalarının oluşturulması. 3- Bu uygunluk haritalarının çok katman analizi sonucu çakıştırılması ile her bir piksel için odaklanılan 4 ana kullanımdan hangisinin o alan için en uygun olduğunun belirlenmesi ve geçerli atamanın yapılması.

2. YÖNTEM VE VERİLER

Araştırmada yöntem olarak nesne tabanlı sınıflandırma kullanılmıştır. Şehir gelişimi için potansiyel alanların belirlenmesi amacıyla nesne tabanlı sınıflandırma yapılırken farklı çalışma alanlarına uygulanabilir bir "karar seti" (ruleset) geliştirilmiştir. Nesne tabanlı sınıflandırma ve kara seti işlemleri için Definiens eCognition Devoloper 8 yazılımı kullanılmıştır. Araştırmada e-Cognition Developer 8 nesne tabanlı yazılım türündeki yazılımlarda kullanılan algoritmalar, sınıflandırmaların düzenlenmesi

konusunda segmentleri daha uygun hale getirmek için yapısal veya dokusal ek bilgilerle tamamlanan bir veya daha fazla görüntü segmentlerini gerektirmektedir (Şekil 1).

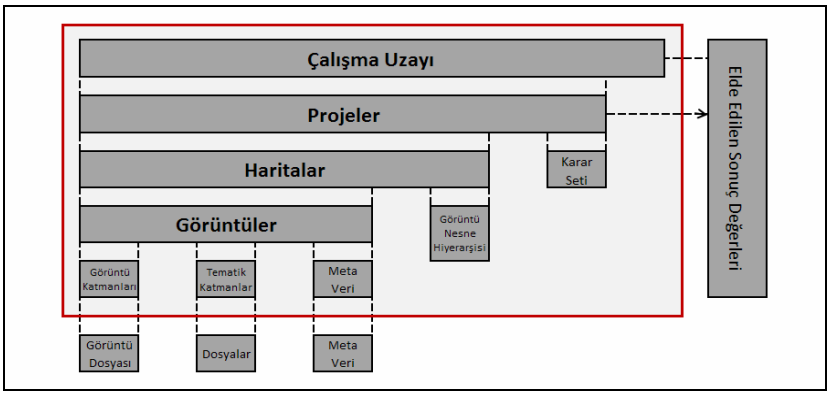

Şekil 1. eCognition proje oluşturmasındaki veri yapısı.

Çalışmada QuickBird 2 görüntüsü kullanılmış (Tablo 1) ve ortorektifikasyon işleminin proje ekibi tarafından yapılması daha uygun ve güvenilir bulunmuştur. Genelde, QuickBird 2 "standart" görüntülerinin ortorektifikasyonu önerilmediğinden, QuickBird 2 orthoready görüntüleri (İstanbul için 3 ve Berlin için 1 çerçeve (frame) çekim programlaması yapılarak temin edilmiştir (Şekil 2).

Tablo 1. Projede kullanılan QuickBird görüntülerinin teknik özelikleri.

Frame 1- 2 Ortho-Ready				
	Pankromatik	MS	Pansharpened (Pan+MS)	Tarih
Mekansal Çözünürlük (m)	0.6	2.4		
Bulutluluk Oranı	0.038	0.038		
Güneş Azimutu (derece)	143.1	143.1		
Güneş Yükseklik Açısı (derece)	69.3	69.3	0.6	18.06.2009
Nadir Açısı (derece)	14.7	14.7		12:48
Referans Yüksekliği (m)	107	107		
Görüntü Boyutu	28760X24192	7190x6048		
Frame 3 Ortho-Ready				
	Pankromatik	MS	Pansharpened (Pan+MS)	Tarih
Mekansal Çözünürlük (m)	0.6	2.4		
Bulutluluk Oranı	0	0		
Güneş Azimutu (derece)	139.7	139.7		08.06.2009
Güneş Yükseklik Açısı (derece)	67.9	67.9	0.6	02:34
Nadir Açısı (derece)	11.5	11.5		
Referans Yüksekliği (m)	107	107		
Görüntü Boyutu	27832X26988	6958X6747		

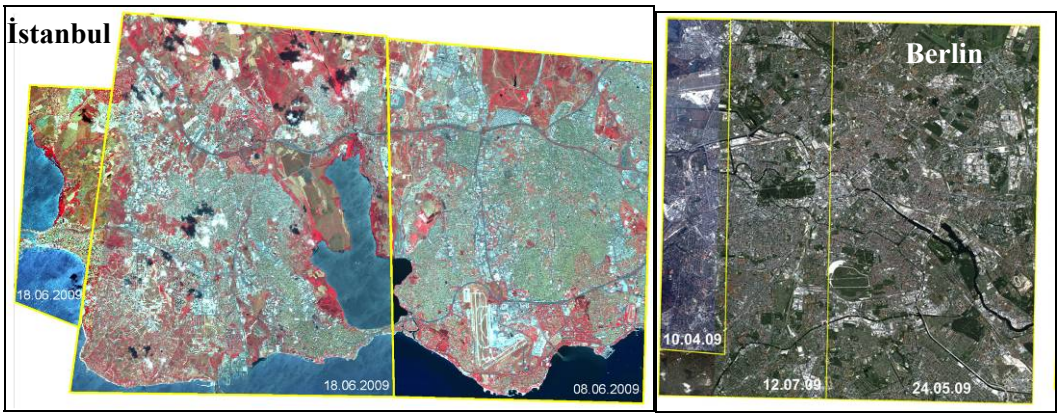

Şekil 2. İstanbul ve Berlin'deki çalışma alanlarının QuickBird görüntüleri.

2.1. Görüntülerin Ön İşlemesi

Orthorektifiye edilmiş görüntüler, yer yüzeyindeki cisimlerin gerçek dünya üzerindeki X ve Y konumlarını temsil eden planimetrik doğruluğu vermektedir. Bu nedenle CBS kapsamında üretilecek ve güncellenecek vektör veriler için gereksinim duyulan ideal referanslardır. Çalışmadaki uygulamalar açısından ortorektifikasyon önemli adımlarından birini oluşturmaktadır. Bu işlem adımı sonrasında ortaya çıkacak olan karesel ortalama hatanın (RMS) düşüklüğü oranında diğer verilerin de QuickBird verileri ile örtüşme oranı artacaktır. Ortorektifikasyon işlemi yapılırken yer kontrol noktaları (YKN) 1/5 000 ölçekli ortofotolardan seçilmiştir. Ayrıca bütün görüntüler için ayrı ayrı işlem yapılmış ve her görüntü için aynı model kullanılmıştır. Ortorektifikasyon işlemi sonucunda görüntülerin RMS oranlarının birbirinden çok farklı olmadığı görülmüştür (Tablo 2). Ortorektifikasyon işleminden sonra sadece RMS değerleri baz alınmayıp QuickBird görüntüleri görsel olarak analiz edilerek yapılan ortorektifikasyon işleminin doğru ve güvenilir olduğu kanıtlanmıştır (Şekil 3).

Tablo 2. Çalışma alanının QuickBird görüntülerinin ortorektifikasyon RMS değerleri.

QuickBird Uydu Verisi	**± RMS**	**# YKN**
Çok Spektrumlu		
09jun18090248-m2as052179426040_01_p001	0.390	12
09jun18091248-m2as052196645010_01_p001	0.319	12
09jun08090234-m2as052179426040_01_p002	0.370	12
Pankromatik		
09jun18090248-m2as052179426040_01_p001	0.397	12
09jun18091248-m2as052196645010_01_p001	0.319	12
09jun08090234-m2as052179426040_01_p002	0.376	12
Pansharpened		
09jun18090248-m2as052179426040_01_p001	0.393	12
09jun18091248-m2as052196645010_01_p001	0.316	12
09jun08090234-m2as052179426040_01_p002	0.379	12

Şekil 3. Ortorektifikasyon sonuçlarının görsel analizi.

2.2. Segmentasyon ve Sınıflandırma

eCognition yazılımında yapılan ilk işlem segmentasyondur ve bu işlemin amacı görüntüden anlamlı nesneler çıkartmaktır. Diğer bir ifade ile, ilgili her nesnenin şekli, bir görüntü nesnesine dayalı olarak gösterilmelidir. Türetilmiş renk ve doku özellikleriyle birleştirilmiş bu şekil, oluşturulan görüntü nesnelerini sınıflandırarak öncelikle görüntünün sınıflandırılması için kullanılmaktadır. Bu nedenle sınıflar, bir sınıf hiyerarşisi içinde düzenlenmektedir. Her sınıf, bir alt sınıf (sub-class) ve üst sınıfa (super class) sahip olabilmektedir ve böylece her sınıfın, bir veya daha fazla üst (süper) sınıflarına ait özellikleri de alt sınıflarında görülmektedir. Ortaya çıkarılacak nesnelerin çok ölçekli sonuçları göz önüne alındığında küçük nesneler, anlamsal bir hiyerarşi oluşturan daha büyük nesneleri yapılandırmak için birleştirilebilmektedir. Aynı şekilde büyük bir nesne, nesne analizinin iki ana yaklaşımına yönelen küçük nesnelere bölünebilmektedir: yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) yaklaşımı (Benz, 2003, eCognition User Guide, 2003 ve URL 1) (Şekil 4). eCognition yazılımındaki her iki yaklaşım aşağıdaki işlemler yapılarak uygulanabilmektedir:

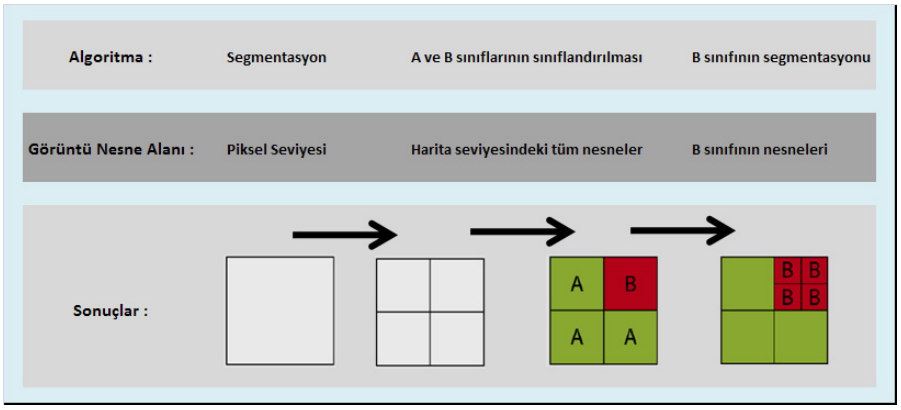

Şekil 4. Değişik nesne alanlarının işlem adımları.

Çoklu-çözünürlüklü segmantasyon işlemi kullanarak görüntü nesnelerinin hiyerarşik yapısı oluşturulmaktadır. Üst katman görüntü segmentleri küçük ölçekli nesneleri, alt katman segmentleri ise büyük ölçekli nesneleri göstermektedir. Sınıflandırılmış nesneleri, sınıflandırma tabanlı segmentasyon için kullanılabilir anlamsal gruplar olarak birleştirerek elde edilen komşu segmentler daha sonra CBS ortamına aktarılıp kullanılabilmektedir. Ayrıca anlamsal gruplar, başka komşuluk analizleri için de geçerlidir. Bu işlemler eCognition yazılımı ile çalışılırken kullanılan temel aşamalardır. İlk iki işlemin yapılması zorunluyken, sonraki iki işlemin uygulanması, yazılımın kullanıcısına ve görüntünün içeriğine bağlı olarak değişebilmektedir. Segmentasyon aşamasında, aşağıdaki parametreler olabildiğince gerçeğe yakın belirlenmelidir (Şekil 5).

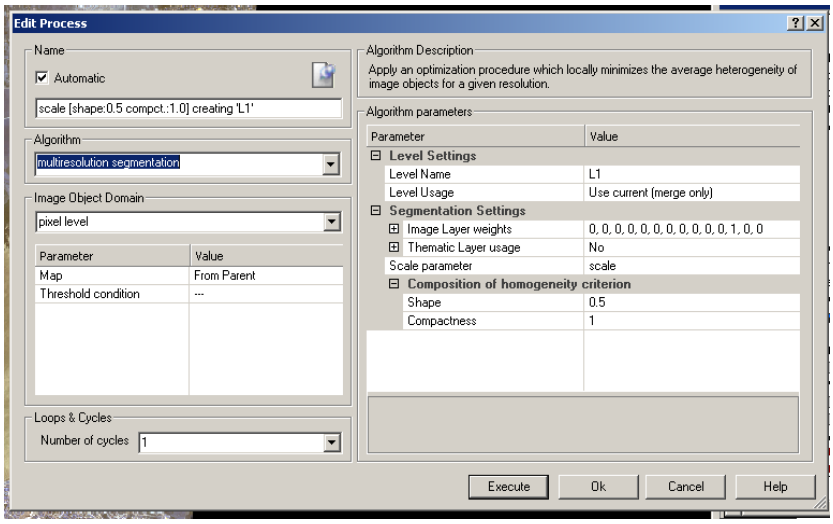

Şekil 5. Segmentasyon işleminde kullanılan parametreler.

Ölçek parametresi (Scale Parameter):

Bu parametre, ortalama nesne boyutunu dolaylı yoldan etkilemektedir. Diğer bir ifade ile bu parametre nesnelerin heterojenliğine izin veren maksimum değeri belirlemektedir. Ölçek parametresi ne kadar büyük seçilirse nesnelerin boyutu da o kadar büyümektedir.

Renk/Biçim (Color/Shape):

Renk ve biçim parametreleri ağırlıklandırılarak farklı yapıda nesneler üretilmektedir. Biçim kriteri ne kadar yüksek olursa, spektral homojenliğin nesne üretimine etkisi de o kadar az olacaktır.

Yumuşaklık/Bütünlük (Smoothness/Compactness):

Biçim kriteri 0'dan büyük olduğunda kullanıcı, nesnelerin daha bütün (yoğun) veya daha yumuşatılmış olması gerektiğine karar verebilmektedir.

Segmentasyon aşamasının ardından görüntülerin sınıflandırma işlemi gelmektedir. eCognition yazılımında iki temel sınıflandırıcı algoritması bulunmaktadır. En yakın komşuluk sınıflandırıcısı ve

bulanık üyelik (fuzzy membership) fonksiyonları. Her ikisi de sınıf tanımcıları olarak görev yapmaktadır. En yakın komşuluk sınıflandırıcısı, kullanıcının her sınıf için karar vermesi gereken örnek nesneler yardımıyla oluşturulacak sınıfları tanımlarken, bulanık üyelik fonksiyonları nesnelerin belirli bir sınıfa ait olduğu veya belli bir seviyede olmadığı yerdeki önemli özellik aralıklarını tanımlamaktadır. Nesne tabanlı sınıflandırma işleminde ilk adım, tüm görüntünün birbirine yakın nesnelerle segmente edilmesidir. Bu çalışmada segmentasyon eCognition Developer 8 kullanılarak uygulanmıştır. Bu yöntem belirli alanların birleştirilmesi şeklinde de ifade edilebilmektedir. Kısaca bu yöntem ikili sistemdeki bir sayaç tarafından üretilen bir kararsızlık matrisinden ardışık kaynak noktaları oluşturmaktadır. Sonrasında her bir kaynak noktasından başlayarak her adımda bir çift komşu görüntü nesnesi geniş bir nesne şeklinde birleştirilmektedir. Birleştirme işlemi lokal homojenlik kriterine bağlı olarak yapılmaktadır. Homojenlik kriteri aşağıda tanımlanmıştır (1).

$$f = \sum_{i=1}^{i=n} W_i \left(n_{merge}\, s_{merge} - (n_{obj1} s_{obj1} + n_{obj2} s_{obj2})\right) \qquad (1)$$

n : Bant sayısı

W_i : Hesaplanan bandın ağırlığı

n_{merge} : Birleştirilen nesnedeki piksel sayısı

n_{obj1} : Nesne 1'deki piksel sayısı

n_{obj2} : Nesne 2'deki piksel sayısı

σ_{merge} : Birleştirilen nesnelerin varyansı

σ_{obj1} : Birinci nesnenin varyansı

σ_{obj2} : İkinci nesnenin varyansı

f, görüntü nesnelerinin boyutları ve n adet görüntü bandının toplamlarıyla ağırlıklandırılmış yerel ton heterojenliğin-den elde edilmektedir. Bu çalışmada tüm Wi'ler için eşit ağırlık değeri =1 alınmıştır.

3. UYGULAMA

Çalışma alanının QuickBird MSS, pankromatik ve pansharpened görüntüleri ortorektifikasyon sonrasında eCognition Developer 8 ile nesne tabanlı sınıflandırma ve analiz işlemlerinde kullanılmıştır. Sınıflandırma aşamasına geçmeden önce sınıflandırma sonucunda ulaşılmak istenen özelliklerin; yani sınıfların tek tek belirlenmesi gerekmektedir. Bu amaçla daha önceden belirlenmiş "Coordination of Information on the Environment" (CORINE) ya da GSE land cover gibi bazı sınıflandırma şemaları kullanılmaktadır. Bu çalışmada şehir ve bölge planlamacılarının ihtiyaçlarını karşılayacak doğrultuda yeni bir sınıflandırma şeması oluşturulmuştur. Bu şema ana hatlarıyla arazi örtüsü ve arazi kullanımı olarak iki kısımdan oluşmaktadır (Şekil 6 ve Şekil 7).

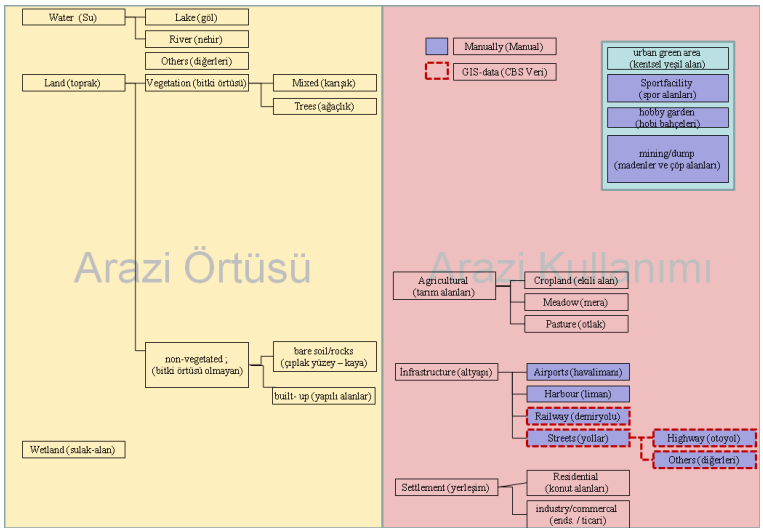

Şekil 6. Çalışmada kullanılan arazi kullanımı/örtüsü sınıfları.

Araştırma amacı doğrultusunda oluşturulacak sınıflandırma işlemleri ile ilgili çeşitli parametrelere bağlı olarak ortak bir karar seti kavramı ve değerleri üzerinde durulacağından karar seti çalışma sistemi seçilmiştir. Eski sürümlerinden farklı olarak eCognition Developer yazılımındaki 'process tree' özelliği analiz aşamalarını kendi içinde ayrı ayrı oluşturabilmektedir. Bu özellik sayesinde görüntü üzerinde yapılan işlemler adım adım oluşturularak karar seti dosyası olarak kaydedilebilmektedir (Şekil 8). Ayrıca, oluşturulan bu dosyalar başka görüntüler ve başka bilgisayarlarda da kullanılabilmektedir. Çalışmadaki 3 farklı araştırma alanından biri olan İstanbul için kullanılan karar seti parametrelerinin, diğer iki çalışma alanı olan Bochum ve Berlin için de uygulanabilirliği konusunda ortak çalışmalar yapılmıştır. Yapılan örnek uygulamalar sonucunda ortak bir karar seti oluşturulmuştur. Oluşturulan karar setinin en önemli avantajı bu üç bölge için de kullanıcıya çalışma alanı ve görüntüyle ilgili karar seti özelleştirme imkanı sağlamasıdır.

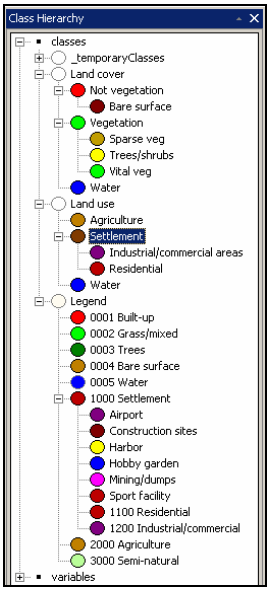

Şekil 7. Sınıf hiyerarşisi

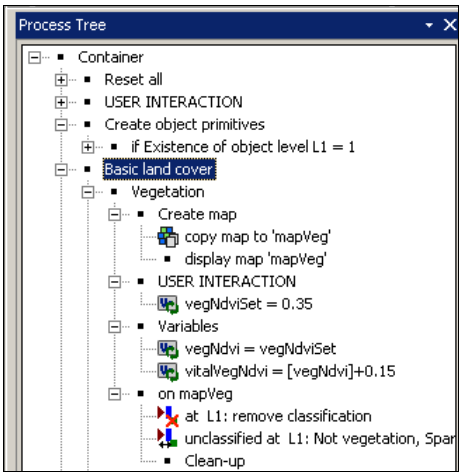

Şekil 8. eCognition içerisindeki "process tree"

Uygulama aşamasında öncelikle eCognition Developer'da da bir çalışma dosyası oluşturulmuştur. eCognition Developer'ın proje dosya uzantısı "dpr"dir. Daha önce önişleme uygulamaları tamamlanan QuickBird MSS, pankromatik ve pansharpened görüntülerinin yazılım içerisinde farklı özelliklerinin kullanılabilmesi amacıyla görüntülere ait bantlar, oluşturulan DPR projesi içerisine aktarılırken 0.6 m proje çözünürlüğü ile örneklenmiştir. Böylece toplamda dokuz bandın farklı özelliklerinden yararlanılmıştır. Projenin amacı olan potansiyel boş alanların belirlenmesi ile ilgili oluşturulan karar seti, proje kapsamında örnek olarak seçilen uygulama alanlarının farklı şehirsel dokulara sahip olmasından dolayı farklılıklar göstermektedir. Her sınıf için segmentasyonda kullanılacak parametreler sınıf hiyerarşisinde o sınıf için belirlenmektedir. Her bir sınıf için belirlenen parametreler Tablo 3'te verilmiştir.

Tablo 3. Tüm sınıflar için belirlenen parametreler.

		Ölçek	Band Ağırlığı	Şekil	Bütünlük (Compactness)
Arazi Örtüsü	Bitki Örtüsü (Vegetation)	50	Nir: 1	0.5	1
	Seyrek Bitki Örtüsü (Sparse Vegetation)	50	Nir: 1	0.5	1
	Ağaç/Çalılık (Trees/Shrubs)	50	Nir: 1	0.5	1
	Canlı Bitki Örtüsü (Vital Vegetation)	50	Nir: 1	0.5	1
	Bitki Örtüsü Olmayan (Not Vegetation)	50	Nir: 1	0.5	1
	Çıplak Yüzey (Bare Surface)	200	Nir: 1	0.3	1
	Su (Water)	500	Blue: 1 Green: 1 Nir: 1 Pan: 1 Red: 1	0.3	1
	Ağaç (Trees)	50	Green: 1 Pan: 2 Red: 1	0.7	1
Arazi Kullanımı	Tarım (Agriculture)	500	Nir: 4 Pan: 1 Red: 1	0.3	1
	Yerleşim (Settlement)	100	Green: 1 Nir: 1 Pan: 3 Red: 3	0.7	1
	Endüstri / Ticari Alanlar (Industry / Commercial Areas)	50	Blue: 4 Green: 1 Nir: 1 Pan: 1 Red: 1	0.7	1
	Konut Alanları (Residential)	100	Green: 1 Nir: 1 Pan: 3 Red: 3	0.7	1

Çalışma kapsamında iki adet karar seti dosyası oluşturulmuştur. Bunlar; otomatik sınıflandırma ile kolay ve doğru belirlenemeyecek sınıflar için geliştirilen manual sınıflandırma karar seti dosyası ile spor alanları, liman, hava alanı ve inşaat alanları gibi sınıflardır (Şekil 9).

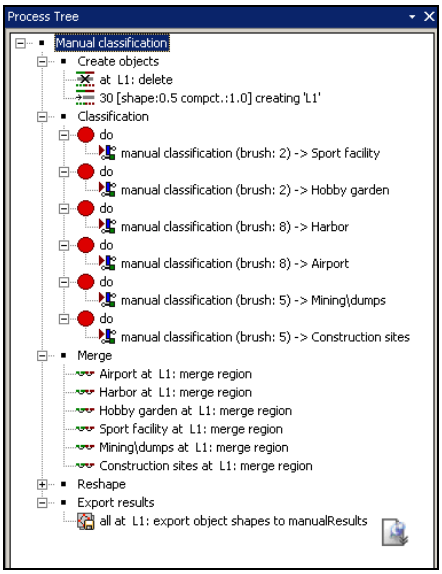

Şekil 9. Manual sınıflandırma için hazırlanan process tree.

Bu aşamada segmentasyon sonrası oluşan görüntüde seçilen bölgeler ilgili sınıflara atanmaktadır. Segmentasyon aşaması ile nesneler oluşturulduktan sonra, nesneler "Brush tool" yardımı ile seçilerek ilgili sınıflara atanmaktadır. 'Merge' komutu ile bu nesneler birleştirilerek, geliştirilen "reshape" algoritması ile daha düz (smooth) bir görünüm elde edilmektedir (Şekil 10). "Export" komutu ile manual sınıflandırma sonuçları bir shape dosyası olarak kaydedilebilmekte ve bu shape dosyası otomatik sınıflandırma sırasında karar seti dosyasına bütünleştirilebilmektedir.

Oluşturulan karar seti dosyasının transfer edilebilir olması için, yani daha sonra farklı görüntü, bilgisayar ya da bölgeler için uygulanabilir olması amacıyla, oluşturulan karar seti dokümanının birçok aşamasına "USER INTERACTION" adı altında bazı parametre değişim bölümleri eklenmiştir. Buradaki değişkenler, bölgelerin ya da görüntülerin değişik özelliklerine göre güncellenerek, hem transfer edilebilir bir karar seti dokümanı oluşturulmuş, hem de sınıflandırma sırasında parametrelere müdahale etme olanağı elde edilmiştir. Otomatik sınıflandırma karar seti dosyası oluşturulurken manual sınıflandırma sonuçları oluşturulan projenin içerisine shape file olarak entegre edilmiştir. Bu aşamadan sonra projenin bazı sınıflarında kullanılacak olan L1 katmanında segmentasyon yapılarak oluşan ana harita "map" bölümü karar seti dökümanına eklenmiştir (Şekil 11).

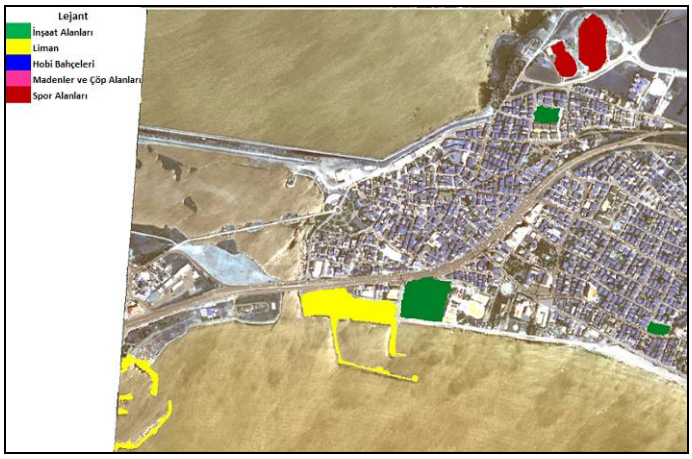

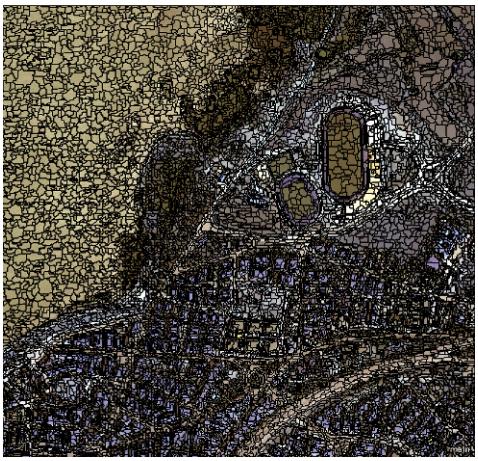

Şekil 10. Manual sınıflandırma ile elde edilen sonuç görüntüsü. **Şekil 11.** L1 katmanında segmentasyon sonucu.

Karar seti genel olarak temel arazi örtüsü ve arazi kullanımı aşamalarından oluşmaktadır. Temel arazi örtüsü bölümünde ana sınıflar; 'bitki örtüsü, bitki örtüsü olmayan ve su' olarak üçe ayrılmaktadır. Bitki örtüsü sınıfı, 'canlı bitki örtüsü, seyrek bitki örtüsü ve ağaç' sınıflarından oluşmaktadır. Bitki örtüsü olmayan sınıf ise 'çıplak yüzey' sınıfından oluşmaktadır. Arazi kullanımı bölümünde ise ana sınıflar, ' tarım ve yerleşim' olarak ikiye ayrılmaktadır. Yerleşim sınıfı, 'endüstri/ticari ve konut alanları' sınıflarından oluşmaktadır. Segmentasyon işleminden sonra nesnelerin sınıflara atanabilmesi için eşik değeri, nesne ilişkisi, büyüklük, yoğunluk vb. parametrelerin sınıflara tanıtılması gerekmektedir (Tablo 4).

Tablo 4. Tüm sınıflara ait kullanılan parametreler.

	Sınıflar	Özellikler
Arazi Örtüsü	Çıplak Yüzey	green / nir > 1
		blue / red > 1
		Mean green > 420
		Standart deviation blue < 10
	Bitki Örtüsü	ndvi >= 0.35
	Ağaç / Çalılık	Mean nir < 650
		Mean red < 140
		Standart deviation pan < 25
		Mean red < 125
		Standart deviation pan < 20
	Canlı Bitki Örtüsü	ndvi >= 0.50
	Su	Mean nir < 350
		Standart deviation pan < 50
Arazi Kullanımı	Tarım Alanları	Area > 5000 m2
		Density > 1.5
		Mean nir > 350
		Standart deviation pan < 20
	Yerleşim	Mean of sub-objects: standart deviation blue(1) > 18
		Rel. Area of sub-objects: Not vegetation(1) > 0.1
	Endüstri / Ticaret Alanları	Mean blue > 700
		ndvi < 0.15
		Standart deviation blue > 25

Her sınıfın ayrı ayrı sınıflandırılması sonucunda oluşan tematik bilgiler sınıflandırma şemasına uygun olarak ilgili sınıflara atanmıştır ve oluşan bu sınıflar yine shape dosyası olarak kaydedilmiştir (Şekil 12).

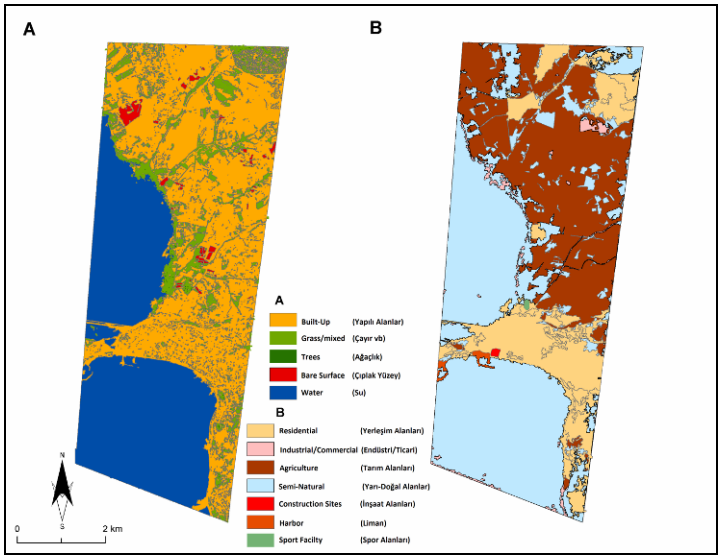

Şekil 12. Genel sınıflandırma sonucu

Şekil 13. Doğruluk analizi için seçilen alanlar

Yapılan nesne tabanlı sınıflandırma sonrası doğruluk analizi için eCogniton yazılımında dört farklı yöntem bulunmaktadır. Çalışma kapsamında görüntü üzerinden seçilen örneklere dayanan "Accuracy

Assestment Based on 'TTA (Training or Test Areas) mask" seçeneği ile sınıflandırma doğruluğu test edileceği için görüntünün ilk segmentasyon yapılmış halinden örnek alanlar seçilerek doğruluk analizi işlemi gerçekletirilmiştir (Şekil 13). Oluşturulan iki ayrı map dosyası için elde edilen doğruluk sonuçları Şekil 14 ve Şekil 15'te verilmiştir. Yukarıda belirtilen işlemlerin aynısı Berlin çalışma alanı için de uygulanmıştır. Uygulanan karar seti sonucu üretilen sınıflandıma görüntüsünün doğruluk analizi ve haritası Şekil 16 ve Tablo 5'te verilmiştir.

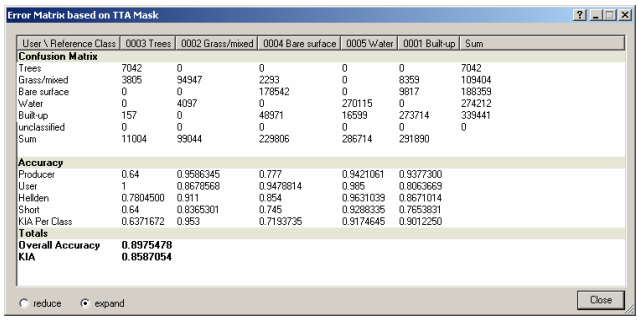

Error Matrix based on TTA Mask

User \ Reference Class	0003 Trees	0002 Grass/mixed	0004 Bare surface	0005 Water	0001 Built-up	Sum
Confusion Matrix						
Trees	7042	0	0	0	0	7042
Grass/mixed	3805	94947	2293	0	8359	109404
Bare surface	0	0	178542	0	9817	188359
Water	0	4097	0	270115	0	274212
Built-up	157	0	48971	16599	273714	339441
unclassified	0	0	0	0	0	0
Sum	11004	99044	229806	286714	291890	
Accuracy						
Producer	0.64	0.9598345	0.777	0.9421061	0.9377300	
User	1	0.8678568	0.9478814	0.985	0.8063669	
Hellden	0.7804500	0.911	0.854	0.9631039	0.8671014	
Short	0.64	0.8365301	0.745	0.9288335	0.7653831	
KIA Per Class	0.6371672	0.953	0.7193735	0.9174645	0.9012250	
Totals						
Overall Accuracy	**0.8975478**					
KIA	**0.8587054**					

reduce expand Close

Şekil 14. Arazi örtüsü doğruluk analizi sonuçları.

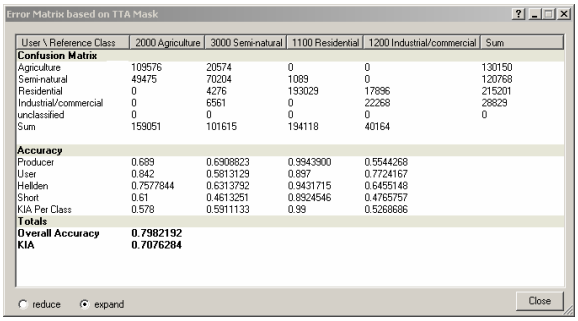

Error Matrix based on TTA Mask

User \ Reference Class	2000 Agriculture	3000 Semi-natural	1100 Residential	1200 Industrial/commercial	Sum
Confusion Matrix					
Agriculture	109576	20574	0	0	130150
Semi-natural	49475	70204	1089	0	120768
Residential	0	4276	193029	17896	215201
Industrial/commercial	0	6561	0	22268	28829
unclassified	0	0	0	0	0
Sum	159051	101615	194118	40164	
Accuracy					
Producer	0.689	0.6908823	0.9943900	0.5544268	
User	0.842	0.5813129	0.897	0.7724167	
Hellden	0.7577844	0.6313792	0.9431715	0.6455148	
Short	0.61	0.4613251	0.8924546	0.4765757	
KIA Per Class	0.578	0.5911133	0.99	0.5268686	
Totals					
Overall Accuracy	**0.7982192**				
KIA	**0.7076284**				

reduce expand Close

Şekil 15. Arazi kullanımı doğruluk analizi sonuçları

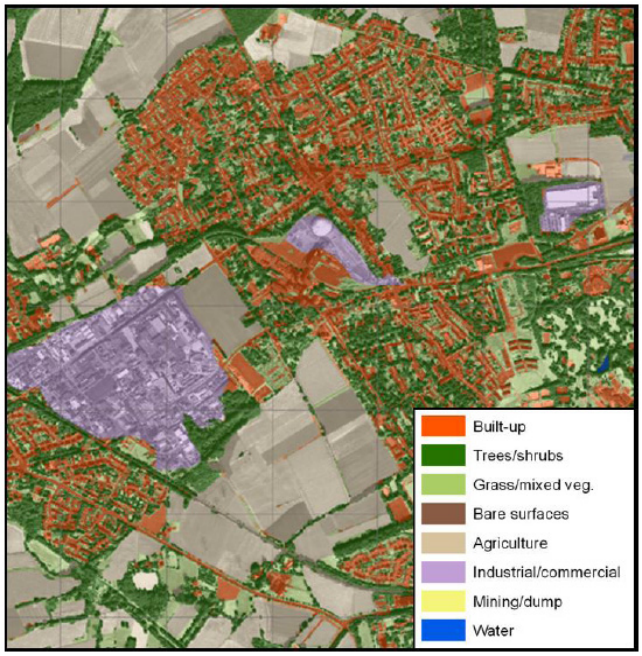

Şekil 16. Berlin çalışma alanının yarı otomatik sınıflandırma sonucu.

Tablo 5. Berlin sınıflandırma sonucu doğruluk analizi.

Ref. \ User	Built-up	Trees\ Shrubs	Grass\ Mixed	Open	Water
Built-up	19634	0	0	1540	143
Trees \shrubs	456	14013	1639	0	67
Grass \mixed	109	1215	10099	1382	0
Open	1660	44	0	9054	0
Water	89	0	0	0	4278
Sum	21948	15272	11738	11976	4488
Algorithm	0.89	0.92	0.86	0.76	0.95
User	0.92	0.87	0.79	0.84	0.98
Accuracy	87.25				

4. SONUÇ

Günümüz uzaktan algılama teknolojilerinde yüksek çözünürlüklü verilerin, zengin bilgi içeriği, piksel tabanlı yaklaşımlarla tam olarak yansıtılamamaktadır. Bu yüzden, uygulanan piksel tabanlı

yaklaşımların yanı sıra nesne tabanlı yaklaşımlar da kullanılmaya başlanmıştır. Nesne tabanlı yaklaşımda ilk olarak mevcut uydu görüntüsü üzerinden gerekli görüntü ön işleme işlemleri yapıldıktan sonra segmentasyon işlemine geçilir. Segmentasyon işleminde, çalışma alanına ait yersel verinin ve elde bulunan uygun vektör bilgisinin altlık olarak kullanılması, otomatik nesne çıkarımını kolaylaştırmakta ve doğruluğunu arttırmaktadır. Sınıflandırma kalitesi, segmentasyonun kalitesine ve oluşan segmentlerin doğru nesneleri uygun geometrik şekillerle ifade etmesine bağlıdır. Bu da kullanılan vektör yapıya bağlı olduğu gibi, bu vektör yapının görüntüye uyuşumu için uygulamanın en başında yürütülen ortorektifikasyon işlemine de bağlıdır. Burada kullanılan dijital yükseklik modeli ve bunun gibi her türlü ek parametre, sınıflandırmanın doğruluğunu çok büyük ölçekte etkilemektedir.

Günümüzde, kentlerin, denetimsiz büyümenin getirdiği sorunlara ve bu çerçevede bireylerin ve toplumun gereksinmelerine nasıl yanıt vereceği konusu, en temel sorulardan birini oluşturmaktadır. İnsanların çevre bilincinin geçmiş yüzyıllara oranla arttığı günümüzde daha kontrollü, akıllı, sürdürülebilir olması gereken geleceğin kentlerini planlamak hedefi yeni çözümler üretilmesine neden olmuştur. Bu çözümlerden biri olan "Akıllı Büyüme" (Smart Growth) kentlerin dağınık gelişimini önlemeyi hedefleyen bir kentsel planlama yaklaşımıdır. Çalışmanın çok kriterli analizler kısmında, CBS ortamında uygunluk ve çok kriterli analizlerle ekolojik ve mevcut alan kullanımlarının yakınlık kriterlerinin bir arada kullanılması ile en uygun alan kullanım atamasının yapılmasını sağlayan bir modelin geliştirilmesi hedeflenmektedir. Halen devam etmekte olan bu projenin sonuçları ileriki aşamalarda daha kapsamlı olarak yayınlanacaktır.

TEŞEKKÜR

Bu projeyi destekleyen TÜBİTAK ve Almanya Eğitim ve Araştırma Bakanlığı'na (BMBF) teşekkür ederiz.

KAYNAKLAR

Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I. Heynen, M., 2003. *Multi-Resolution, Object-Oriented Fuzzy Analysis of Remote Sensing Data for GIS-Ready Information*, ISPRS Journal of Photogrammetry & Remote Sensing, 239-258

eCognition User Guide 3., 2003. Definiens Imaging, p.3.2-108

Hofmann, P., 2001a. *Detecting Informal Settlements from Ikonos Image Data Using Methods of Object Oriented Image Analysis - An Example From Cape Town (South Africa)*, Jürgens, Carsten (Editor): Remote Sensing of Urban Areas/Fernerkundung in urbanen Räumen. (Regensburger Geographische Schriften, Heft 35), Regensburg.

Hofmann, P., 2001b. *Detecting Urban Features From Ikonos Data Using an Object-Oriented Approach*, In: RSPS 2001, Geomatics, Earth Observation and the Information Society, 2001

URL 1., eCognition Yazılımı İnternet Sitesi, *Yayınlar-Haziran 2004*, http://www.definiens-imaging.com/ documents/reference.htm, (12.08.2010).