BİNA VE YOL ALANLARININ ÇOK YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU GÖRÜNTÜLERİNDEN ÇİZGE-TABANLI YENİ BİR YÖNTEM İLE OTOMATİK TESPİTİ

Ali Özgün OK

Yrd. Doç. Dr., Nevşehir H.B.V. Üniversitesi, Jeodezi ve Fotogrametri Mühendisliği Bölümü, 2000 Evler, 50300, Nevşehir
ozgunok@nevsehir.edu.tr, ozguneo@gmail.com

ÖZET

Bu çalışmada çok yüksek çözünürlüklü tek bir optik uydu görüntüsünden bina ve yol alanlarının otomatik olarak belirlenmesi için çizge-tabanlı bir yöntem geliştirilmiştir. Yöntem temel olarak üç aşamadan oluşmaktadır. Birinci aşamada bitki örtüsü ve gölge maskeleri otomatik olarak elde edilmiştir. Devamında bu aşamada sadece bina bölgeleriyle ilgili bilgilerin elde edilmesi amaçlanmıştır. Bu nedenle gölge maskesi ve görüntü çekim anına ait güneşin konum bilgisinden yararlanılmıştır. Yine bu aşamada bina alanları iki-etiketli olarak gerçekleştirilen (bina ve diğerleri) ve her gölge nesnesi için ayrı ayrı olarak uygulanan yinelemeli çizge-kesme yöntemiyle tespit edilmiştir. İkinci aşamanın amacı tüm görüntü düzleminde bulunan bina bölgelerine ait bilgileri ortak kullanarak görüntüyü dört farklı sınıfa (bina, gölge, bitki ve diğerleri) ayırmaktır. Bu aşamada daha önceden otomatik olarak etiketlenmiş olan bölgeler (bina, gölge ve bitki örtüsü) ve herhangi bir etiket almamış olan diğer alanlar dört etiketli bir çizge-tabanlı optimizasyon işlemine tabi tutulmuştur. Üçüncü aşamada ise bina ve yol nesnelerine ait nihai bölgelerin belirlenmesi amaçlanmıştır. İlk olarak yol kısımlarına ait olması muhtemel bölgeler ikinci aşamadaki optimizasyon sonucunda bulunun diğer sınıfa ait bölgelerden otomatik olarak çıkarılmıştır. Devamında bu bilgi yol sınıfına ait sınıflandırma bilgisinin elde edilmesi için kullanılmış ve beş farklı etiket ile (bina, gölge, bitki, yol ve diğerleri) nihai çizge-tabanlı optimizasyon gerçekleştirilmiştir. Bu son aşama, bütün görüntüyü otomatik olarak beş sınıfa ayırmakta ve bu sayede görüntüye ait bina ve yol bölgeleri tanımlanmaktadır. Yöntemin test edilmesi amacıyla farklı GeoEye-1 uydu görüntülerinden (0.5 m) yedi test alanı seçilmiştir. Bina bölgeleri için sırasıyla yaklaşık %83 ve %89 genel kesinlik ve geri-getirme oranı hesaplanmıştır. Öte yandan yol alanları için genel kesinlik ve geri-getirme oranları sırasıyla %62.9 ve %71.5 olarak bulunmuştur. Geliştirilen yöntemin literatürdeki diğer çalışmalara göre en önemli özelliği ve üstünlüğü, bina ve yol bölgelerini beraber bulmaya yönelik ortak bir yol izlemesi ve bu sayede bu iki sınıf arasındaki hatalı sınıflamaları en alt düzeye çekmeye çalışmasıdır.

Anahtar Sözcükler: Bina Tespiti, Yol Tespiti, Çizge-tabanlı Yöntem, Çok Sınıflı Optimizasyon, Uydu Görüntüsü.

ABSTRACT

AUTOMATED DETECTION OF BUILDING AND ROAD REGIONS FROM VERY HIGH RESOLUTION SATELLITE IMAGES THROUGH A NEW GRAPH-BASED STRATEGY

In this study, a new graph-based approach is developed for the detection of buildings and roads from a single very high resolution optical satellite image. The approach relies on three main stages. In Stage I, vegetation and shadow masks are collected automatically. Thereafter, this stage aims to extract information only related to building regions. Therefore, we benefit from the shadow mask and the sun angles of image acquisition. Finally in this stage, building regions are identified by iterative graph-cuts designed in a two-label (building and others) partitioning performed for each shadow component independently. The goal of Stage II is to integrate the global evidence into the approach, and to improve the extent of the classification in the entire image domain to four distinct classes (building, shadow, vegetation, and others). In this stage, the previously labelled regions (building, shadow, and vegetation) as well as the other areas having no label are involved in a four-label graph optimization. Stage III aims to eventually characterize the regions belonging to buildings and roads. Firstly, the regions that might belong to road segments from the class others are extracted. Thereafter, this information is used to collect information related to the class road and a final graph optimization is performed for five different labels (building, shadow, vegetation, road and others). This final step automatically divides the entire image into five classes where the regions belonging to buildings and roads are eventually identified. Seven test sites from different GeoEye-1 satellite images (0.5 m) are selected to evaluate the approach.Overall precision and recall ratios are computed as 83.0% and 89.4%, respectively, for buildings. Besides, overall precision and recall ratios are computed as 62.9% and 71.5%, respectively, for roads. The main novelty and superiority of the developed approach over the other approaches in the literature is that it follows an integrated way to detect regions both for buildings and roads, and in this way, attempts to minimize misclassifications that may occur between these two classes.

Keywords: Building Detection, Road Detection, Graph-based Strategy, Multi-label Optimization, Satellite Image

1. GİRİŞ

Çok yüksek çözünürlüklü (≤ 1 m) uydu görüntülerinde bir kentsel alanın sınırları içerisinde yer alan insan yapımı nesneler arasında en önemli iki sınıfı binalar ve yollar temsil etmektedir. Bunun temel nedeni ise insan nüfusunun büyük çoğunluğunun bu iki sınıf ile devamlı olarak etkileşimde bulunmasıdır. Bu iki sınıfa ait uydu görüntülerinden otomatik olarak bilgi edinilebilmesi kentsel alanların gözlemlenmesi/tespit edilmesi, değişikliklerin analizi, insan nüfusunun tahmini, telekomünikasyon gibi çok çeşitli uygulama alanlarına girdi sağlayabilecektir. 30 yılı aşkın bir

süredir çok sayıda araştırmacı bina ve yol nesnelerinin tespitine yönelik önemli sayıda araştırma gerçekleştirmiş ve bu konuda çok sayıda bilimsel makale yayımlanmıştır. Bu çalışmanın amacı çok yüksek çözünürlüklü tek bir uydu görüntüsünden bina ve yol nesnelerine ait olan bölgelerin otomatik olarak belirlemesine olanak sağlayacak çizge-tabanlı bir yöntem geliştirmektir. Bu nedenle literatür taraması kısmında sadece tek bir optik uydu görüntüsünden otomatik olarak bina ve/veya yol nesnelerinin tespit edilmesini amaçlayan bilimsel çalışmalar özetlenmiştir.

Binaların otomatik olarak tespit edilmesine yönelik öncü niteliğindeki çalışmalar tek bir görüntüde bina hipotezlerini oluşturmak üzere görüntüdeki kenar/çizgi gibi temel özniteliklerin gruplandırılması ile gerçekleştirilmiştir. Ayrıca bu konuda önerilen çok sayıda yöntem binaların gölgelerinden de önemli ölçüde yararlanmıştır (örn.: Lin ve Nevatia, 1998; Katartzis ve Sahli, 2008; Akçay ve Aksoy, 2010; Izadi ve Saeedi, 2012). Tek bir görüntüye yönelik olarak gerçekleştirilen diğer çalışmalarda görüntülerdeki çok-bant bilgisinden faydalanılmış ve genelde bir sınıflandırma gerçekleştirilerek bina bulma probleminin çözülmesi hedeflenmiştir (örn.: Benediktsson vd., 2003; Ünsalan ve Boyer, 2005; Inglada, 2007; Senaras vd., 2013). Bu çalışmalardan başka olarak aktif konturlar (e.g. Karantzalos ve Paragios, 2009), Markov Rastgele Alanları (MRA) (e.g. Katartzis ve Sahli, 2008), kernel-tabanlı yaklaşımlarda (Sirmacek ve Ünsalan, 2011) aynı zamanda halen süregelen araştırma konuları arasındadır. Güncel yapılan iki çalışmada, binaların otomatik olarak tespit edilmesine yönelik olarak gölge tabanlı etkin yaklaşımlar sunulmuştur (Ok vd., 2013; Ok, 2013).

Tek bir görüntüden yol alanlarının tespitine yönelik olarak gerçekleştirilen çalışmaların sayısı da oldukça fazladır. Bu bağlamda gerçekleştirilen öncü çalışmalar arasında kurala dayalı sistemler ve bilgiye dayalı yaklaşımlar popülerdir. Çeşitli çalışmalarda yol alanlarının belirlenmesi problemine bir çözüm bulabilmek amacıyla morfolojik işlemler uygulanmıştır (örn.: Shi ve Zu, 2002; Guo vd., 2007). Aynı zamanda görüntüdeki çok bant bilgisinin de kullanıldığı sınıflandırma stratejileri de önemli ölçüde araştırılmıştır (örn.: Wiedemann ve Hinz, 1999; Mena ve Malpica, 2005). Bu bağlamda uygulanan yöntemlerden bazıları arasında destek vektör makineleri (örn.: Huang ve Zhang, 2009), sinir ağları (örn.: Das vd., 2011) ve MRA'lar (örn.: Katartzis vd., 2001) sayılabilir. Nitekim yapılan bir çalışmada Mayer vd. (2006) altı adet farklı yol bulma yaklaşımını karşılaştırmış ve yöntemlerin yol merkezlerini belirleyebilme başarısını ortaya koymuştur. Son yıllarda yapılan çalışmalardan birinde Tournaire ve Paparoditis (2009) yol işaretlerinin belirlenmesine yönelik Belirgin Nokta İşlemine (Marked Point Process) dayalı bir yaklaşım geliştirmiştir. Ayrıca Poullis ve You (2010) yolların belirlenmesi amacına yönelik olarak algısal gruplama ve çizge kesme yönteminin ortak kullanımına dayalı bir yöntem önermiştir. Das vd. (2011) yol ağlarının belirlenebilmesi amacıyla değişmez niteliklere ve sinir ağlarına dayalı bir yaklaşım sunmuştur. Bu konuda yapılan farklı bir çalışmada Ünsalan ve Sirmacek (2012) olasılık temelli bir yaklaşım kullanmak suretiyle yol ağlarını tespit etmiştir. Güncel bir başka çalışmada, hava fotoğraflarından yol bölütlerine ait olan bölgeleri daha doğru bir şekilde belirleyebilmek amacıyla koşullu MRA esasına dayanan bir yaklaşım önerilmiştir (Wegner vd., 2013).

Yukarıda belirtilen çalışmalarda araştırmacılar ya binalar ya da yollar olmak üzere sadece tek bir nesneye odaklanmış ve bu bağlamda sadece tek bir nesneye ait alanları belirleyebilme amacına uygun olan yaklaşımlar önermişlerdir. Bu iki sınıfın birbirinden farklı karakteristikleri olmasına rağmen her iki nesne grubu aslında çeşitli yönlerden birbirini tamamlayıcı niteliktedir; şöyle ki binaların birçoğuna bir yol bağlantısı mevcut olmakta veya bir yolun herhangi bir bölümü veya tamamı çevresinde yer alan binaların yükseklikleri sebebiyle çekim geometrisine de bağlı olarak bina alanlarıyla örtüşebilmektedir (Hinz vd., 2001). Bu nedenle, bina ve yol alanlarının tespiti her iki sınıf bilgisini de içeren ortak bir yöntemle ele alınması durumunda bu iki farklı sınıfın saptanmasına yönelik çalışmaların performansı üzerinde olumlu bir etkisi olabilecektir. Günümüze kadar bu tür bütünleşmiş bir davranış gerçekleştiren çok az sayıda çalışma mevcuttur. Bu çalışmalardan ilk ikisi olan Hinz ve Baumgartner (2000) ve Hinz vd. (2001) yol alanlarının belirlenmesi için çevresel etkilerin önemini vurgulamıştır. Bu bilim insanları bina ve yollara ilişkin hem küresel, hem de yerel çevreye dayanan bir yaklaşım önermişlerdir. Fakat önerdikleri yaklaşım yolların belirlenmesini kolaylaştırabilmek için gölge ve bina alanlarını bir Sayısal Yüzey Modelinden elde etmektedir. Ünsalan ve Boyer (2005) çizge-tabanlı bir strateji kullanarak bina ve yol tespiti gerçekleştirmiştir. Önerdikleri yaklaşım doğrultusunda tekli ve ikili kısıtlamalara sahip olan aktif konturların kullanılması suretiyle yol ağları belirlenmiş ve bu alanların dışında kalan bölgeler bina alanları olarak kabul edilmiştir. Ancak önerilen yaklaşım içerdiği varsayımlar nedeniyle sadece Kuzey Amerika'da gözlemlenen bina ve yol nesneleri için geçerlidir. Bir diğer çalışmada Aytekin vd. (2012) bina ve yolların bulunması amacıyla bir yöntem önermiştir. Bu çalışmada önerilen yaklaşım bölütleme tabanlı olup bina ve yollara ait bölgeler ilkel morfolojik işlemler kullanılmak suretiyle ayırt edilmiştir.

Bu çalışmada çok yüksek çözünürlüklü tek bir optik uydu görüntüsünden bina ve yol nesnelerine ait olan bölgelerin otomatik olarak belirlenmesine olanak sağlayacak çizge-tabanlı bir yöntem geliştirilmiştir. Yöntem temel olarak üç ana aşamadan oluşmaktadır. Birinci aşamada ilk olarak bitki örtüsü ve gölge maskeleri otomatik olarak elde edilmiştir. Devamında bu aşamada sadece bina bölgeleriyle ilgili bilgilerin elde edilmesi amaçlanmıştır. Bu nedenle gölge maskesi ve görüntü üst verisinde yer alan görüntü çekim anına ait güneşin konum bilgisinden yararlanılmıştır. Bu sayede bina nesneleri ile gölgeleri arasında var olan mekânsal ilişki görüntü düzleminde oluşturulmuştur. Bu aşamada bina alanları iki etiketli olarak gerçekleştirilen (bina ve diğerleri) ve her gölge nesnesi için ayrı ayrı olarak uygulanan yinelemeli çizge-kesme yöntemiyle tespit edilmiştir. İkinci aşamanın amacı tüm görüntü düzleminde

bulunan bina bölgelerine ait bilgileri ortak kullanarak görüntüyü dört farklı sınıfa (bina, gölge, bitki ve diğer) ayırmaktır. Bu aşamada daha önceden otomatik olarak etiketlenmiş olan bölgeler (bina, gölge ve bitki örtüsü) ve herhangi bir etiket almamış olan diğer alanlar tüm görüntü üzerinde gerçekleştirilen dört etiketli bir çizge-tabanlı optimizasyon işlemine tabi tutulmuştur. Üçüncü aşamada ise bina ve yol nesnelerine ait nihai bölgelerin belirlenmesi amaçlanmıştır. Bu aşamada ilk olarak yol kısımlarına ait olması muhtemel bölgeler ikinci aşamadaki optimizasyon sonucunda bulunan diğer sınıfa ait bölgelerden otomatik olarak çıkarılmıştır. Devamında bu bilgi yol sınıfına ait sınıflandırma bilgisinin elde edilmesi için kullanılmış ve beş farklı etiket ile (bina, gölge, bitki, yol ve diğer) nihai çizge-tabanlı optimizasyon gerçekleştirilmiştir. Bu son aşama bütün görüntüyü otomatik olarak beş sınıfa ayırmakta ve bu sayede görüntüye ait bina ve yol bölgeleri ortak bir şekilde elde edilmektedir.

Çalışmanın işlem adımları metnin ilerleyen bölümlerinde açıklanmaktadır. Buna göre; Bölüm 2'de geliştirilen yaklaşım tanıtılmıştır. Bölüm 3'te yöntemin sonuçları ortaya konulmuş ve elde edilen bulgular tartışılmıştır. Son bölüm olan 4. bölümde ise çalışmadan elde edilen sonuçlar özetlenmiş ve gelecekte yapılması planlanan çalışmalara değinilmiştir.

2. GELİŞTİRİLEN YÖNTEM

Geliştirilen yöntemin işlem adımları sırasıyla aşağıda açıklanmıştır. Bu çalışmada kullanılan bazı yöntemler daha önce yapılan ve yayımlanan iki çalışmada detaylarıyla açıklanmıştır (Ok vd., 2013; Ok, 2013). Bu nedenle bu iki çalışma ile ilgili olan kısımlar bu bölümde kısaca özetlenmiştir.

Bu çalışmada önerilen yaklaşım tek bir keskinleştirilmiş çok-bantlı (M, Y, K ve YKÖ) ortogörüntüyü kullanmaktadır. Ayrıca görüntünün çekim zamanına ait güneş açıları (azimuth ve zenith) ile ilgili bilgiler görüntüye ait üst veriden (metadata) otomatik olarak çekilmektedir. Sağlıklı bitki örtüsünün bulunduğu alanları tespit edebilmek amacıyla Normalize Diferansiyel Bitki İndeksinden (NDVI) yararlanılmıştır. Söz konusu bu indeks sağlıklı bitki örtüsünün gözlemlendiği yerlerde yüksek değerler üretmek amacıyla tasarlanmış olup bu yüksek değerler genellikle bitki örtüsü bulunan alanları göstermektedir. Bu çalışmada bitki örtüsü maskesini (M_V) otomatik olarak hesaplayabilmek amacıyla Otsu metoduna (Otsu, 1975) dayanan histogram eşikleme metodu kullanılmıştır (Şekil 1b). Gölge alanların otomatik tespit edilmesi için ise güncel bir indeksten faydalanılmıştır (Teke vd., 2011). Bu indeks Renk Tonu-Doygunluk-Yoğunluk (HSI) renk uzayının Yoğunluk ve Doygunluk bileşenleri ile hesaplanan bir orana dayanmakta ve HSI renk uzayına ise uydu görüntüsünün yalancı renk birleşiminden geçilmektedir (NIR, R, G). Gölge alanlarını otomatik belirlemek için tıpkı bitki örtüsü tespitinde de faydalanıldığı üzere Otsu'nun metodu uygulanmıştır. Fakat bu yöntemle elde edilen maske bitki örtüsü ve gölge alanlarını ortak olarak gösterdiği için bitki örtüsünün bulunduğu alanlar gölge maskesi (M_S) elde etmek amacıyla çıkarılmıştır. Bu çalışmada bulunan gölge maskesinin temizlenmesi ve bina bulma amacına uygun hale getirilmesi amacıyla Ok (2013)'te önerilen son-işleme yaklaşımı kullanılmış ve temizlenmiş gölge maskesi (M_{PS}) elde edilmiştir (Şekil 1c).

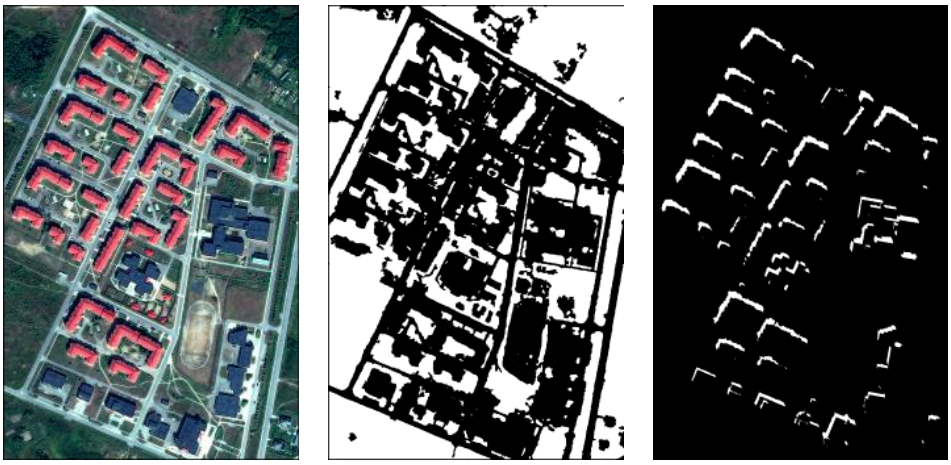

(a) (b) (c)

Şekil 1. (a) Keskinleştirilmiş GeoEye-1 görüntüsü (K-Y-M), (b) bitki örtüsü maskesi (M_V), (c) temizlenmiş gölge maskesi (M_{PS}).

2.1 Bina ve Gölge Arasındaki Mekânsal İlişkinin Oluşturulması

Bir gölge nesnesi olan B (örneğin her biri M_{PS} gölge maskesinde 8-yönlü bağlantılı olan alanlar) ve bir α yönünde 0 ile 1 arasında olasılık değerleri içeren çizgi şeklinde (L) bir yapıtaşı elemanı $v_{L,\alpha,\sigma,\kappa}$ verildiğinde bir görüntüdeki gölge nesnesinin etrafında verilen α yönündeki bölge $\beta_\alpha(B)$ aşağıdaki şekilde tanımlanmaktadır (Ok vd., 2013):

$$\beta_\alpha(B) = \left(B^{per} \oplus v_{L,\alpha,\sigma,\kappa}\right) \cap B^c \quad . \tag{1}$$

B^{per} gölge nesnesi olan B'nin çevresini oluşturan pikselleri, B^C ise gölge nesnesi olan B'nin tümleyicisini, $\oplus$ ve $\cap$ operatörleri ise sırasıyla morfolojik genleşme ve bulanık kesişimi göstermektedir. Bu işlem sonucunda elde edilen bölge değerleri 0 ile 1 aralığında olup bu değerler gölge nesnesinden uzaklaştıkça azalmakta ve α açısı ile belirlenen tek bir yönde nesnenin çevresiyle tanımlanan bir alanı oluşturmaktadır. Eşitlik 1'de kullanılan yapıtaşı elemanı $v_{L,\alpha,\sigma,\kappa}$ (Şekil 2a) birbirinden farklı iki yapıtaşı elemanının birleştirilmesi ($*$) suretiyle oluşturulmuştur:

$$v_{L,\alpha,\sigma,\kappa} = v_{L,\kappa,\alpha} * v_{\sigma,\kappa} \quad . \tag{2}$$

Eşitlik 2'de $v_{\sigma,\kappa}$ kernel boyutu κ olan yön bağımsız ve olasılık değerleri 0 ile 1 arasında içeren bir yapıtaşı elemanını, $v_{L,\kappa,\alpha}$ ise sadece α yönünde 0 ve 1 ikili değeri içeren yapılandırma elemanını tanımlamaktadır. Yine aynı formülde bulunan L bir çizgiyi ve α ise çizginin yönlendirildiği açı değerini betimlemektedir. Eşitlik 1 ile elde edilen bölgeler görüntü üzerindeki tüm gölge alanları için üretilmektedir (Şekil 2b). Fakat bir görüntüde insan yapımı nesnelerin yanı sıra bünyesinde ağaç barındıran bitkisel alanlarda gölge üretebilmektedir. Bu nedenle üretilen her gölge nesnesinin böyle bir bitkisel alana ait olup olmadığı üretilen $\beta_\alpha(B)$ bölgeleri ve bitki örtüsü maskesi (M_V) kullanılarak incelenmiştir. Bu işlemin sonucunda bitki örtüsüne bağlı olarak üretilen olasılık bölgeleri temizlenmiştir.

2.2. Aşama I: İlk Bina Bölgelerini Tespit Etme Amacına Yönelik Yerel İşleme

Bu aşamada bina alanlarının ön tespiti hedeflenmiş ve bu hedefe ulaşmak için yerel olarak her gölge alanı için tekrarlanan bir yöntem tasarlanmıştır. Bu aşamada her bir gölgeye ait bina bölgesi diğerler alanlardan ayırt edilmeye çalışılmıştır. Bu nedenle görüntüde bina olmayan herhangi bir sınıf tek bir kategori olarak düşünülmüştür. Bu ikili sınıflandırma problemini çözmek amacıyla yinelemeli iki etiketli çizge-kesme optimizasyonundan (GrabCut) (Rother vd., 2004; Boykov ve Kolmogorov, 2004) yararlanılmıştır.

GrabCut yöntemi esasen görüntüleri yarı otomatik olarak ön/arka plan bölümlere ayırmaktadır. Kullanıcı tarafından etkileşimli olarak etiketlenen bir grup ön ve arka plana ait pikseller işaretlendiğinde bu yöntem çizge teorisini kullanarak görüntüdeki tüm pikselleri ön/arka plan olarak etiketlemektedir. Daha önceki bir çalışmada GrabCut yaklaşımı kullanıcı etkileşimi olmaksızın bina tespiti hedefine yönelik olarak geliştirilmiştir (Ok vd., 2013). Geliştirilen yaklaşımda ön plana (binaya) (T_F) ve arka plana (bina olmayan) (T_B) karşılık gelen pikseller gölge alanları ve gölgeden üretilen bölgelerin kullanılmasıyla otomatik olarak etiketlendirilmektedir. Otomatik etiketleme için ilk olarak T_F alanları üretilmektedir. Bunun için bölge olasılık değerlerine ikili bir eşik (n_1, n_2) uygulanmaktadır. Tam olarak güvenilir bir T_F elde edebilmek için tek bir parametre (d) barındıran bir düzeltme prosedürü de uygulanmaktadır. Devamında GrabCut yönteminin uygulanacağı hedef bölge (ROI) tanımlanmaktadır. Bu aşamada, her bir gölge nesnesi için boyutu gölge bölgesinin güneşin geliş açısının tersi yönünde büyütülmesinden sonra otomatik olarak tespit edilen bir sınırlayıcı alan üretilmektedir. Bu alan seçildikten sonra içerisinde arka planla ilgili bilgilere karşılık gelen pikseller yine otomatik olarak belirlenmektedir: ROI bölgesinin dışındaki alanların yanı sıra aynı zamanda bu alan içindeki gölge bitki örtüsü alanlarının tamamı T_B olarak etiketlenmektedir.

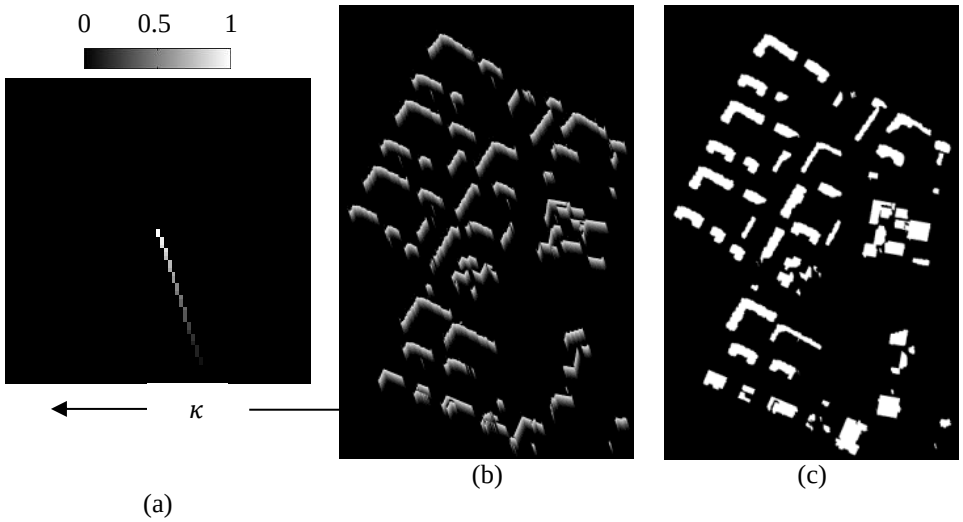

(a) (b) (c)

Şekil 2. (a) Yapıtaşı elemanı ($v_{L,\alpha,\sigma,\kappa}$). (b) Şekil 1c'deki gölge maskesi için üretilen olasılık bölgeleri ve (c) I. Aşama sonucunda elde edilen bina alanları.

2.3. Aşama II: Bina Bölgelerinin Belirlenmesi için Global İşleme

Birinci aşamadan sonra bina bölgeleri hemen hemen hiçbir aşırı saptama olmaksızın nispeten az bir bütünlükle tespit edilmektedir (Şekil 2c). İkinci aşamanın amacı bütün görüntüdeki bina bölgelerine yönelik toplanan kanıtları birlikte kullanmak suretiyle bina bölgelerini daha iyi belirlemektir. Birinci aşama sonunda tüm görüntü daha önceden hesaplanan bitki örtüsü (M_V) ve gölge alanları ile (M_{PS}) birlikte dört sınıfa ayrılabilmektedir. Öncelikle bulunan bina, bitki ve gölge alanları ilk üç sınıfa ait etiketleri belirlemektedir. Devamında bu üç sınıfa karşılık gelmeyen bölgeler dördüncü bir sınıf olan "diğer" şeklinde tanımlanmıştır (Şekil 3a).

Bu aşamada Ok (2013) tarafından önerilen yaklaşım uygulanmıştır. Bu yaklaşım dört etiketli bir çizge-kesme optimizasyonu geliştirilmiştir. Bir görüntüdeki tüm pikseller $\mathbf{z} = (z_1, z_2, \ldots, z_N)$ ve tüm olası etiketler $L \in \{1, \ldots l\}$ olarak tanımlandığında (ki burada l=4'dür), bu aşamada amaç L'de yer alan etiketleri tüm $\mathbf{z}$ verilerine optimum olacak şekilde sınıflamaktır. II. aşamanın başında her bir pikselin (z_i) bir ilk etiket değeri (α_n) mevcut olup bu değer $\alpha_n \in \{1, 2, 3, 4\}$ her bir sınıf etiketine (L) tekabül etmektedir. Sınıflama için bu çalışmada Gibbs enerji fonksiyonu kullanılmış (Rother vd., 2004) ve bu fonksiyondaki veri enerjisinin hesaplanmasında *K* bileşenli Gauss Karışım Modelleri (GMM) kullanılmıştır. Enerji fonksiyonunda bulunan mekânsal düzleştirme enerjisi için ise Rother vd. (2004) tarafından önerilen üstel düzgünlük terimi kullanılmıştır. Çizge-kesmenin kullanılması suretiyle çoklu etiket optimizasyonunun enerjisini minimum kılabilmek için düzgünlük terimine ve L etiket sayısına bağlı olan özel bir çizge oluşturulmaktadır. Optimizasyon işlemi için etkin bir yaklaşım α-genişleme algoritmasıdır ve bu yaklaşımının detayları (Boykov vd., 2001) çalışmasında açıklanmıştır. Yaklaşım, çok-etiketli enerji fonksiyonlarının optimizasyonunda global minimum değerine ulaşamasa da, o değere yakın sonuçlar ürettiği kanıtlanmıştır.

Dört-etiketli optimizasyon sonucunda bina bölgelerinin birçoğu doğru bir şekilde belirlenmektedir. Fakat bazı bina olmayan bölgeler yine de bina olarak hatalı bir şekilde etiketlenebilmektedir. Bunun temel nedeni ise bina alanlarıyla bina olmayan alanlar arasındaki spektral benzerliklerdir. Bu aşamada bu problemi en aza indirebilmek amacıyla yeni bir gölge doğrulama yaklaşımı geliştirilmiştir (Ok, 2013). Bu doğrulama işlemi iki seviyeden oluşmaktadır. İlk seviyede, bulunan tüm bina alanlarında bina ve gölge ilişkisi olup olmadığı teyit edilmektedir. Bu teyit sırasında daha önceden gölge maskesi tarafından üretilen gölge olasılık bölgeleri kullanılmaktadır. İkinci seviyede ise teyit edilemeyen bina bölgeleri için dört etiketli optimizasyon sonucundan sonra üretilen gölge bilgisinden faydalanılmıştır. Bu bina alanları, optimizasyon sonucunda elde edilen gölge alanları ile tekrardan kontrol edilmekte ve eğer bu alanlar için bina ve gölge ilişkisi bulunabiliyor ise teyit edilmektedir. Böylece bu seviye sonunda başlangıçta gerçekte görüntü üzerinde gölge olarak yer alan fakat gölge maskesinde yer almamış olan gölge bölgeleri de kullanılarak bina bölgelerini daha doğru bir şekilde belirlemek mümkün olabilmektedir (Şekil 3b). Son olarak gölge bilgisi ile doğrulanamayan tüm bina bölgeleri diğer sınıfına dâhil edilmektedir (Şekil 3c).

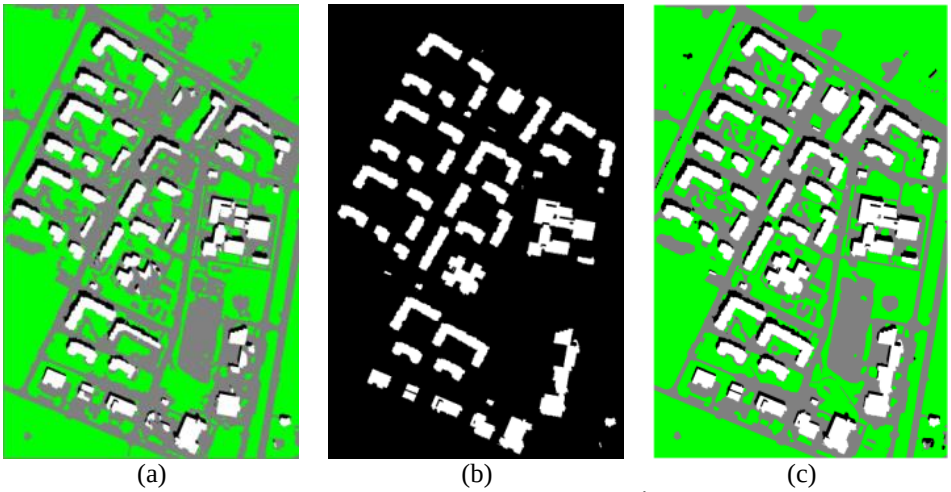

(a) (b) (c)

Şekil 3. (a) İkinci aşamanın girdisi, (b) doğrulanan bina alanları ve (c) İkinci aşamanın çıktısı. Bina, bitki örtüsü, gölge ve diğerleri sırasıyla beyaz, yeşil, siyah ve gri renkle gösterilmiştir.

2.4. Aşama III: Bina ve Yol Alanlarının Ortak Belirlenmesi

İkinci aşamadan sonra elde edilen diğer sınıfına ait bölgeler, bina, bitki örtüsü ve gölge alanları hariç olmak üzere herhangi bir sınıfı içerebilmektedir. Bu nedenle ikinci aşamadan sonra sadece diğer sınıfına ait olan bölgeleri ele alırsak bu sınıf örneğin yollar, açık araziler, kentsel bir alandaki araçlar, park bölgeleri ve benzeri unsurları içermektedir (Şekil 4a). İkinci aşamadan sonra elde edilen dört etiketli optimizasyon sonucunun başarısına rağmen, halen bazı bina bölgeleri diğer sınıfına ait olarak etiketlenebilmekte (görüntü çekimine bağlı olarak görünmeyen

gölge bölgeleri nedeniyle) veya tam tersi olarak bazı bina olmayan bölgeler için gölge ilişkisi yanlışlıkla bulunabilmektedir (köprüler ve bina olmayan yüksek insan yapılar nedeniyle). İşte bu sebeplerden dolayı bu aşamada hedef ikinci aşamadan elde edilen bilgilerin kullanılması suretiyle muhtemelen yollara ait olan bölgeleri ayırt etmektir. Ancak Şekil 4a'da görüldüğü üzere diğer sınıfına ait olan bölgeler oldukça karmaşık yapıda olup yol alanları basit bir son-işleme ile bulmak mümkün olmamaktadır. Bu nedenle bu aşamada, yolların ayrı bir sınıf halinde belirlendiği önceki sınıflandırmanın beş sınıfı içerecek şekilde genişletilmesi amaçlanmıştır.

Bu aşamada ilk olarak yol bölütlerine ait olabilecek olan temsil niteliğindeki bölgeler otomatik olarak belirlenmiş ve görüntü üzerinde beş etiketli çizge-tabanlı optimizasyon gerçekleştirilmiştir. Bu amaca yönelik olarak yol bölgelerine ait olması mümkün olmayan alanların yol olması kuvvetle muhtemel bölgelerden temizlenmesi gerekmektedir. Das vd. (2011) yol bölgelerinin yol olmayan bölgelerden ayırt edilebilmesine yönelik etkin bir yöntem önermiştir. Özetle ifade etmek gerekirse bu yöntemde ilk olarak yol bölgelerinin ayırt edilebilmesi için bölge bölütlemesi (RPS) kullanılmakta ve daha sonra elde edilen yol hipotezlerini filtrelemek ve doğrulamak için ise orta eksen dönüşümü (MAT) tekniğini uygulanmaktadır. Bu çalışmada da buna benzer bir yol izlenmiştir. İlk olarak, yol alanlarından örneğin park bölgeleri gibi kısımları temizleyebilmek için RPS yaklaşımı uygulanmış ve kuvvetle muhtemel yol olabilecek bölgelere ait bilgileri toplamak amacıyla MAT yaklaşımı geliştirilmiştir. Bu çalışmada yollara ait tek bir varsayım kullanılmıştır: yolların genişliği çok keskin bir şekilde değişiklik göstermemektedir. Yol olması kuvvetle muhtemel alanlar belirlendikten sonra 5-etiketli çizge-tabanlı optimizasyon için ihtiyaç duyulan yol bilgisi bu muhtemel alanların etrafında bir tampon bölge tanımlanarak toplanmıştır (Şekil 4b). Bu son optimizayon aşamasında toplam beş sınıfı kullanılmaktadır. Bu sınıflar bina, yol, bitki örtüsü, gölge ve diğerleri şeklindedir. Son işleme kısmında ise optimizasyon sonucundan (Şekil 4c) bina ve yol olarak etiketlenen bölgeler çekilmiş ve nihai bina sınıfı sonuçları için son olarak ikinci aşamanın sonunda uygulanan gölge kontrolü tekrardan uygulanmıştır.

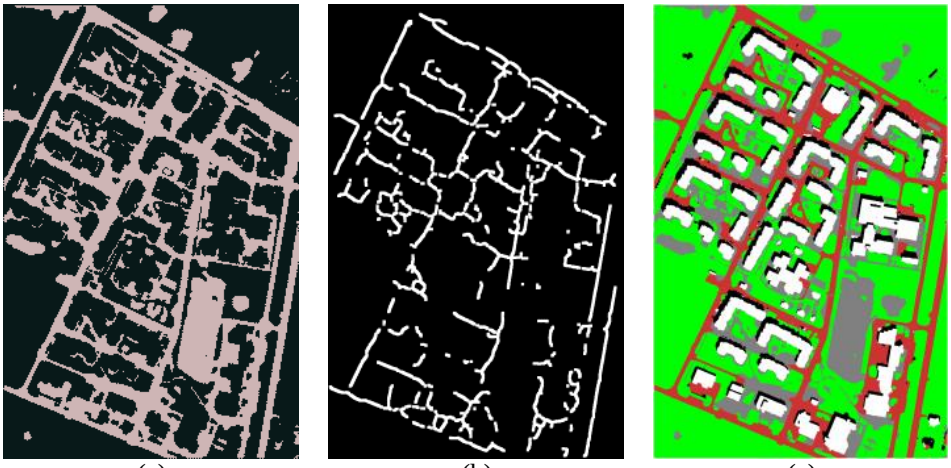

(a) (b) (c)

Şekil 4. (a) Diğer sınıfına ait alanlar, (b) yol sınıfı girdisi ve (c) Üçüncü aşamanın çıktısı. Bina, yol, bitki örtüsü, gölge ve diğerleri sırasıyla beyaz, kırmızı, yeşil, siyah ve gri renkle gösterilmiştir.

3. SONUÇLAR VE TARTIŞMA

Bu çalışmada kullanılan GeoEye-1 (50 cm) test görüntüleri, 4-bantlı (M, Y, K, YKÖ) ve 11 bit radyometrik çözünürlüğe sahiptir. Önerilen yaklaşımın sağlıklı bir şekilde değerlendirilmesi amacıyla farklı çekim koşullarının yanı sıra kentsel alan ve bina karakteristikleri açısından da farklılıklar gösteren yedi test görüntüsü seçilmiştir. Bu görüntülerdeki bina ve yol referans verileri deneyimli bir operatör tarafından çizilmiştir. Elde edilen sonuçların kalitesini değerlendirebilmek amacıyla piksel-tabanlı kesinlik, geri getirme ve F_1 skoru performans ölçütleri (Aksoy vd., 2012) kullanılmıştır. Önerilen yöntem herhangi bir operatör desteği olmaksızın çalışabildiğinden yöntemin ihtiyacı olan parametreler tanımlandığında hızlı bir şekilde kullanılabilmektedir. Birinci ve ikinci aşama için gereksinim duyulan bütün parametreler daha önce yapılan bir çalışmada geniş kapsamlı bir şekilde araştırılmıştır (Ok, 2013). Bu nedenle bu çalışmada üçüncü aşama için gereksinim duyulan parametreler incelenmiş ve bütün test görüntüleri için kullanılacak parametreler sabitlenmiştir.

Elde edilen görsel sonuçlar Şekil 5'te sunulmuştur. Bu sonuçlara göre geliştirilen yaklaşım hem binaların hem de yolların tespit edilmesi için etkin bir yöntem olarak görünmektedir. Bina alanları, örneğin çatı rengi, dokusu, şekil, boyut ve yönelim gibi test görüntülerindeki karmaşık bina karakteristiklerine rağmen oldukça başarılı bir şekilde belirlenmiştir. Aynı zamanda geliştirilen yaklaşım yol alanlarının gölge vb. nedenlerle kapanmaması durumunda birçok yol bölgelerini de tespit edebilmektedir. Nitekim Çizelge 1'de elde edilen sonuçlar bu yorumları desteklemektedir. Bina için hesaplanan genel kesinlik ve geri getirme oranları sırasıyla %83.0 ve %89.4'tür. Yine bina sınıfı için yedi test görüntüsü için hesaplanan F_1 skoru yaklaşık olarak %86 civarındadır. Öte yandan, yol sınıfı

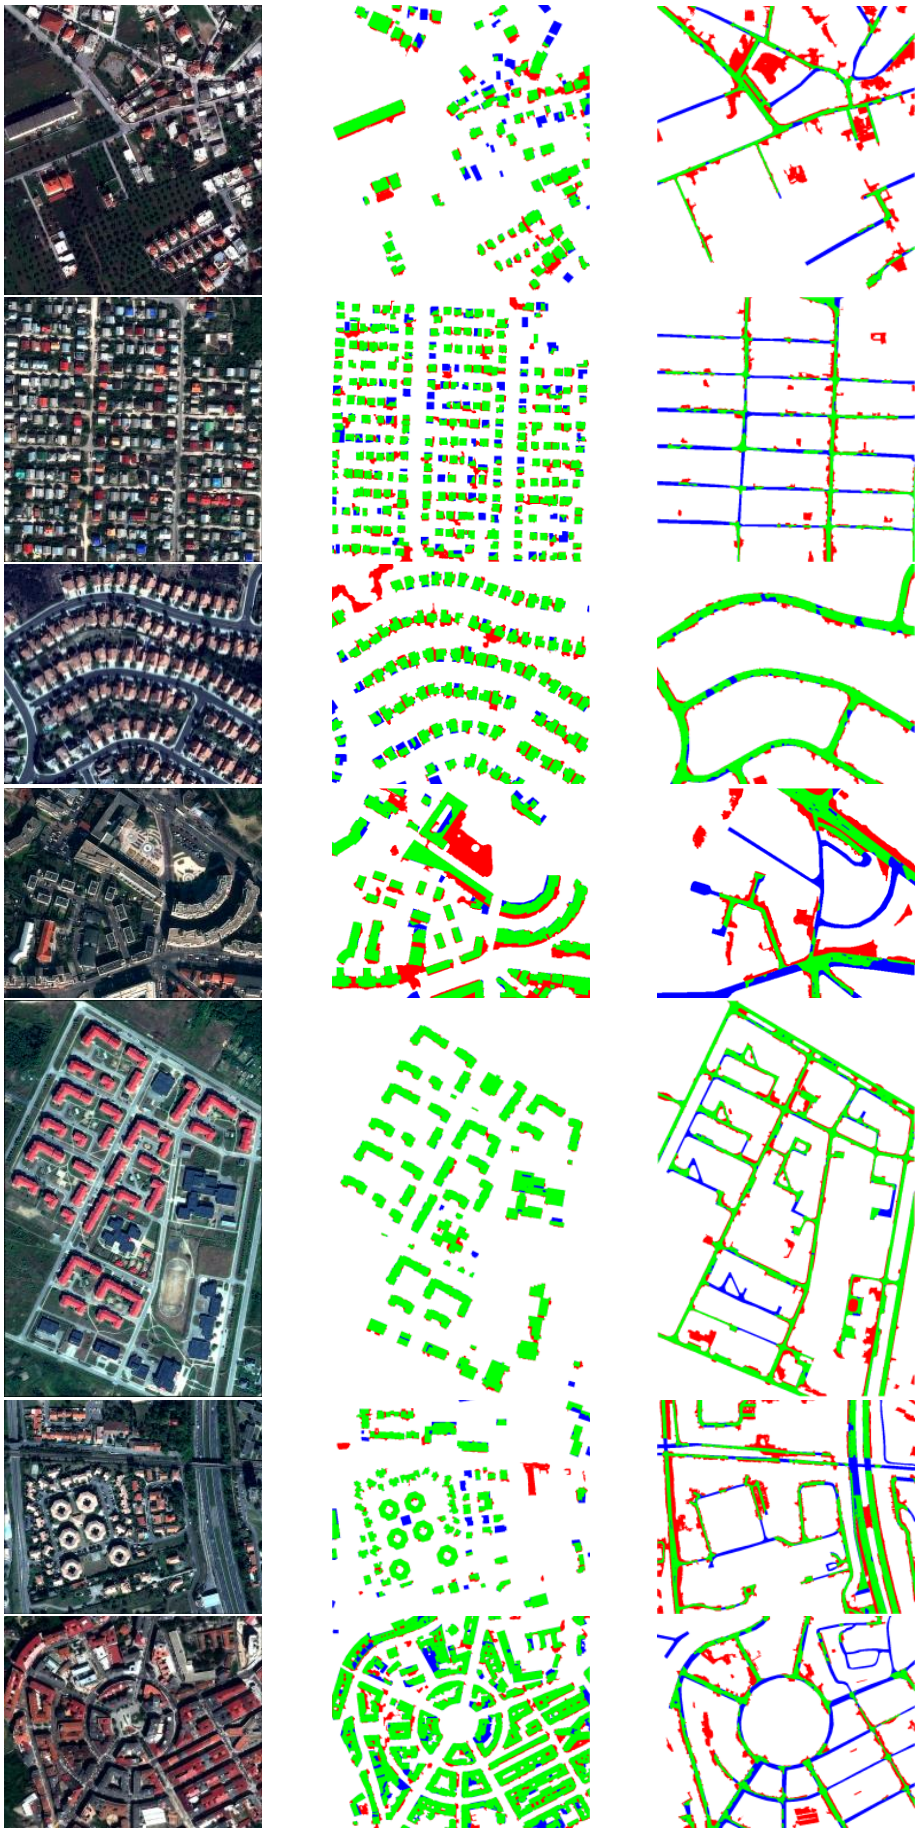

Şekil 5. (ilk sütun) Test veriseti (#1-7, K-Y-M), (ikinci sütun) tespit edilen bina alanları ve (üçüncü sütun) tespit edilen yol bölgeleri. Doğru-pozitif, yanlış-pozitif ve yanlış-negatif bölgeler sırasıyla yeşil, kırmızı ve mavi renklerle gösterilmiştir.

Çizelge 1. Geliştirilen yaklaşımın piksel-tabanlı sonuçları.

Test Alanı	Performans (%)					
	Bina			Yol		
	Kesinlik	*Geri getirme*	*F_1-skoru*	*Kesinlik*	*Geri getirme*	*F_1-skoru*
#1	74.0	81.8	77.7	41.6	69.1	51.9
#2	77.4	82.2	79.7	62.8	52.8	57.4
#3	76.9	89.3	82.6	84.3	91.3	87.7
#4	67.1	92.9	77.9	50.0	50.8	50.4
#5	92.8	96.5	94.6	72.6	87.1	79.2
#6	84.8	87.7	86.2	58.7	77.7	66.9
#7	87.1	90.4	88.7	56.9	52.1	54.4
Toplam	83.0	89.4	86.1	62.9	71.5	66.9

için genel kesinlik ve geri getirme oranları sırasıyla %62.9 ve %71.5 olarak hesaplanmıştır. Bu ise yaklaşık olarak %67'ye tekabül eden bir F_1 skoruna karşılık gelmektedir. Test görüntülerindeki zorluklar ve karmaşık görüntüleme şartları dikkate alındığında, geliştirilen yaklaşımın bina ve yol alanlarının ortak belirlenmesine yönelik gelecek vadeden bir performansa sahip olduğu düşünülmektedir.

Şekil 5'te verilen sonuçlara göre önerilen yaklaşımın binalara yönelik olarak oldukça başarılı olduğu yönünde güçlü bir izlenim oluşmakta ve bu bağlamda tespit edilen bölgelerin bina alanlarını temsil edici bir nitelikte olduğu değerlendirilmektedir. Görsel sonuçlardan anlaşılabildiği üzere binaların iyi bilinen karmaşık karakteristiklerinden etkilenmeden ve kesin bir sınırlamaya maruz kalmadan bina bölgelerinin çoğu başarılı bir şekilde tespit edilebilmektedir. Aynı zamanda bu yaklaşımın bazı durumlar hariç olmak üzere bina bölgelerini diğer bölgelerden belirgin bir şekilde ayırt edebildiği görülmektedir. Tüm test alanları düşünüldüğünde, en düşük kesinlik oranı olan %67.1 dört numaralı test görüntüsü için elde edilmiştir. Bu ise görüntüde belirgin olan geniş yanlış saptamadan kaynaklanmaktadır. Maalesef bu görüntüde aşırı saptamanın oluştuğu kısımdaki beşik çatının bir bölümü hatalı olarak gölge olarak tespit edilmiştir. Bunun sonucu olarak birinci aşamada otomatik olarak seçilen T_F bölgesi binanın çevresinde bulunan unsurlara karşılık gelen pikselleri de içermiş ve bu nedenle sonuçta aşırı saptama ortaya çıkmıştır. Geliştirilen yaklaşım bina alanlarını sadece gölge bilgisinden tespit etmektedir. Bu nedenle spektral yansıma değeri gölgeye çok yakın olan fakat gölge olmayan büyük alanların görüntüde mevcut olması halinde hatalı belirlemeler ortaya çıkabilmektedir (örneğin üç numaralı test görüntüsünün üst sol köşesinde görülen iki hatalı bölge gibi). Ayrıca iki insan yapımı nesnenin, binalar ve köprüler, oluşturduğu gölgeler ayırt edilememektedir. Bu nedenle araç trafiği için yoğun olarak kullanılan büyük köprülerde yanlışlıkla bina olarak etiketlenebilmektedir. Bu hata kaynağına örnek altı numaralı test alanında görülebilmektedir. Bu aşamada, yukarıda belirtilen problemler var olsa da, geliştirilen yaklaşımın birbirinden farklı bina çatı renkleri, dokuları ve şekilleri için genel bir yöntem olduğu, farklı çekim ve karmaşık şehir alanlarında dahi başarılı sonuçlar üretmesi ve bina alanlarını gerçeğe yakın bir şekilde belirleyebilme yeteneği olduğu kanıtlanmıştır.

Şekil 5'te elde edilen sonuçlar geliştirilen yaklaşımın yol alanlarını diğer nesnelerle (örneğin bina veya ağaç gibi) kapatılmaması durumunda tespit edebilme yeteneğine sahip olduğunu göstermektedir. Bir diğer ana problem ise bu nesnelerin (#4 ve #7) oluşturduğu gölgeler nedeniyle ortaya çıkmaktadır. Yoğun binaların bulunduğu kentsel alanlarda yol tespit performansı özellikle görüntünün çekim anına ait güneş açılarına (azimuth ve zenith) bağlı bulunmaktadır. Bu nedenle görüntü çekiminde güneş açılarının uygun olmadığı durumlarda (örneğin geniş zenith açısı) yoğun bir kentsel alandaki yol alanlarının tamamını belirlemek mümkün olamayacaktır. Yol alanlarının belirlenmesine yönelik vurgulanması gereken bir diğer önemli husus ise çizge-tabanlı optimizasyon sırasında uygulanan düzgünlük varsayımıdır. Her ne kadar sınıflama sırasında arzulanan düzgünlük seviyesi tek bir parametre ile kolay bir şekilde kontrol edilebilse de yol bölümlerine ait olan dar yolları tespit etmek her zaman mümkün olamamakta ve bu da yol alanları için hesaplanan geri-getirme oranlarını düşürmektedir. Ancak yukarıda belirtilen bütün bu zorluklara rağmen geliştirilen yaklaşım yol tespiti için tek ve basit bir varsayımdan yararlanmakta olup bina ve yol alanlarının tespiti için operatör tarafından toplanan herhangi bir bilgi kullanmamaktadır. Bu nedenle geliştirilen yaklaşım, yol sınıfı içinde başarılı olarak kabul edilmektedir.

4. SONUÇLAR

Bu çalışmada tek bir (çok-bantlı) uydu görüntüsünden bina ve yollara ait alanların otomatik olarak tespit edilebilmesi için yeni bir çizge-tabanlı yaklaşım sunulmuştur. GeoEye-1 görüntülerinden seçilen yedi adet test görüntüsü üzerinde yapılan değerlendirmeler, geliştirilen yaklaşımın neticesinde bina ve yol alanlarının ortak bir şekilde belirlenebilme potansiyeline sahip olduğunu göstermektedir. İlerleyen çalışmalarda, yol sınıfı için otomatik olarak bilgilerin toplandığı üçüncü aşama iyileştirilecektir. Kentsel bir alan düşünüldüğünde en önemli hedeflerden

birisi büyük köprü nesnelerini bina alanlarından ayırt etmektir. Böylece bina ve köprü nesneleri arasında mantıksal bir ayrımın yapılmasını sağlayabilecek bir yöntem geliştirilebilecektir. Güncel yapılan bir çalışmada Wegner vd. (2013) yüksek komşuluklu MRA'ların yollara ait olan bölgeleri daha başarılı bit şekilde temsil edebildiğini göstermiştir. Bu nedenle bu bilgide daha ileri düzeyde yapılacak olan araştırmalara yönelik ilginç bir konu teşkil etmektedir. Son olarak ise elde edilen bina alanı sınırlarının ve yol ağı ana hatlarının diğer verilerle ortak kullanılabilmesi amacıyla basitleştirilmesi gerekliliğidir. Bu nedenle gelecek çalışmalarda bu yönde ilerlemeler yapılması da planlanmaktadır.

TEŞEKKÜR

Bu çalışmada kullanılan GeoEye-1 test verileri HAVELSAN A.Ş. tarafından sağlanmıştır.

KAYNAKLAR

Akçay, H.G., Aksoy, S., 2010. Building detection using directional spatial constraints. In: IEEE International Geoscience and Remote Sensing Symposium (IGARSS), pp. 1932-1935.

Aksoy, S., Yalniz, I.Z., Tasdemir, K., 2012. Automatic detection and segmentation of orchards using very high resolution imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(8), 3117-3131.

Aytekin, Ö., Erener, A., Ulusoy, İ., Düzgün, Ş., 2012. Unsupervised building detection in complex urban environments from multispectral satellite imagery, *International Journal of Remote Sensing*, 33(7), 2152-2177.

Benediktsson, J.A., Pesaresi, M., Arnason, K., 2003. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9), 1940-1949.

Boykov, Y., Kolmogorov, V., 2004. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(9), 1124-1137.

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

Das, S., Mirnalinee, T.T., Varghese, K., 2011. Use of salient features for the design of a multistage framework to extract roads from high-resolution multispectral satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 49(10), 3906-3931.

Guo, D., Weeks, A., Klee, H., 2007. Robust approach for suburban road segmentation in high-resolution aerial images. *International Journal of Remote Sensing*, 28(2), 307-318.

Hinz, S., Baumgartner, A., 2000. Road Extraction in Urban Areas supported by Context Objects. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 33(B3), pp. 405-412.

Hinz, S., Baumgartner, A., Mayer, H., Wiedemann, C., Ebner, H., 2001. *Road Extraction Focussing on Urban Areas*. Automatic Extraction of Man-Made Objects from Aerial and Space Images (III). Balkema Publishers, Rotterdam, pp. 255-265.

Huang, X., Zhang, L., 2009. Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines. *International Journal of Remote Sensing*, 30(8), 1977-1987.

Inglada, J., 2007. Automatic recognition of man-made objects in high resolution optical remote sensing images by SVM classification of geometric image features. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62(3), 236-248.

Izadi, M., Saeedi, P., 2012. Three-Dimensional polygonal building model estimation from single satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 50(6), 2254-2272.

Karantzalos, K., Paragios, N., 2009. Recognition-driven two-dimensional competing priors toward automatic and accurate building detection. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1), 133-144.

Katartzis, A., Sahli, H., 2008. A stochastic framework for the identification of building rooftops using a single remote sensing image. *IEEE Transactions on Geoscience and Remote Sensing*, 46(1), 259-271.

Katartzis, A., Sahli, H., Pizurica, V., Cornelis, J., 2001. A model-based approach to the automatic extraction of linear features from airborne images. *IEEE Transactions on Geoscience and Remote Sensing*, 39(9), 2073-2079.

Lin, C., Nevatia, R., 1998. Building detection and description from a single intensity image. *Computer Vision and Image Understanding*, 72(2), 101-121.

Mayer, H., Hinz, S., Bacher, U., Baltsavias, E., 2006. A test of automatic road extraction approaches. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36(3), pp. 209-214.

Mena, J.B., Malpica, J.A., 2005. An automatic method for road extraction in rural and semi-urban areas starting from high resolution satellite imagery. *Pattern Recognition Letters*, 26(9), 1201-1220.

Ok, A.O., Senaras, C., Yuksel, B., 2013. Automated detection of arbitrarily shaped buildings in complex environments from monocular VHR optical satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 51(3), 1701-1717.

Ok, A.O., 2013. Automated detection of buildings from single VHR multispectral images using shadow information and graph cuts. *ISPRS Journal of Photogrammetry and Remote Sensing*, 86, 21-40.

Otsu, N., 1975. A threshold selection method from gray-level histograms. *Automatica*, 11, 285-296.

Poullis, C., You, S., 2010. Delineation and geometric modeling of road networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(2), 165-181.

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

Senaras, C., Özay M., Vural, F. Y., 2013. Building detection with decision fusion. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(3), 1295-1304.

Shi, W., Zhu, C., 2002. The line segment match method for extracting road network from high-resolution satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 40(2), 511-514.

Sirmacek, B., Ünsalan, C., 2011. A probabilistic framework to detect buildings in aerial and satellite images. *IEEE Transactions on Geoscience and Remote Sensing*, 49(1), 211-221.

Teke, M., Başeski, E., Ok, A.Ö., Yüksel, B., Şenaras, Ç., 2011. *Multi-Spectral False Color Shadow Detection*, Photogrammetric Image Analysis. Springer, Berlin, Heidelberg, pp. 109-119.

Tournaire, O., Paparoditis, N., 2009. A geometric stochastic approach based on marked point processes for road mark detection from high resolution aerial images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(6), 621-631.

Ünsalan, C., Boyer, K.L., 2005. A system to detect houses and residential street networks in multispectral satellite images. *Computer Vision and Image Understanding*, 98(3), 423-461.

Ünsalan, C., Sirmacek, B., 2012. Road network detection using probabilistic and graph theoretical methods. *IEEE Transactions on Geoscience and Remote Sensing*, 50(11), 4441-4453.

Wegner, J.D., Montoya, J., Schindler, K., 2013. A higher-order CRF model for road network extraction. In: *IEEE Conference on Computer Vision and Pattern Recognition*, Portland, USA.

Wiedemann, C., Hinz, S., 1999. Automatic extraction and evaluation of road networks from satellite imagery. In: *International Archives of Photogrammetry and Remote Sensing*, 32(3-2W5), pp. 95-100.