

Çok yüksek çözünürlüklü uydu görüntülerinden kentsel alanlardaki binaların ve yolların otomatik tespiti

Ali Özgün Ok*

Jeodezi ve Fotogrametri Müh., Nevşehir H.B.V. Üniversitesi, Nevşehir, Türkiye

Özet

Cilt: 3
Sayı: 1
Sayfa: 69-79
Kasım 2016

Bu çalışmada çok yüksek çözünürlüklü uydu görüntülerinden kentsel alanlardaki bina ve yol alanlarının eğitimsiz olarak tespiti için bir yöntem sunulmuştur. Yöntem üç aşamadan oluşmaktadır. Birinci aşamada gölge ilgisi ve olasılık haritaları kullanılarak sadece bina bölgeleriyle ilgili bilgiler elde edilmiştir. İlk olarak, bina nesnelere ait gölge alanlar tespit edilmiş ve güneşin konum bilgisinden yararlanılarak binalar ve gölgeler arasında yönlü mekânsal ilişki modellenmiştir. Devamında her gölge alanı ayrı ayrı olarak ele alınmış ve ilk bina alanları iki-etiketli olarak gerçekleştirilen yinelemeli çizge-kesme yöntemiyle tanımlanmıştır. İkinci aşamanın amacı görüntüyü otomatik olarak dört sınıfa ayırmaktır: bina, gölge, bitki ve diğerleri. Bu aşamada daha önceden bina, gölge ve bitki örtüsü olarak etiketlenmiş olan bölgeler ve herhangi bir etiket almamış olan diğer alanlar dört etiketli bir çizge-tabanlı optimizasyon işlemine tabi tutulmuştur. Son aşama ise bu sınıflamayı yol sınıfını da dâhil ederek beş sınıfa çıkarmayı hedeflemektedir. Bu amaçla, yol kısımlarına ait olması muhtemel bölgeler çıkarılmış ve bu bilgi optimizasyon işlemine dahil edilmiştir. Bu son aşama nihai olarak bina ve yol bölgelerini tanımlamaktadır. Çok yüksek çözünürlüklü GeoEye-1 veri setinden seçilen on iki adet test görüntüsü üzerinde yapılan değerlendirmeler, sunulan yaklaşımın bina ve yol alanlarını tek bir çizge-tabanlı yöntem altyapısı ile belirleyebilme yeteneğine sahip olduğunu göstermektedir.

Anahtar Sözcükler

Bina Tespiti, Yol Tespiti, Olasılık Haritaları, Çok Sınıflı Çizge-tabanlı Optimizasyon, Uydu Görüntüsü

Abstract

Automated Detection of Buildings and Roads in Urban Areas from VHR Satellite Images

Volume: 3
Issue: 1
Page: 69-79
November 2016

In this paper, we present an unsupervised approach to detect regions belonging to buildings and roads in urban areas from very high resolution (VHR) satellite images. The proposed approach consists of three main stages. In the first stage, we extract information that is only related to building regions using shadow evidence and probabilistic fuzzy landscapes. First, the shadow areas cast by building objects are detected, and the directional spatial relationship between buildings and their shadows is modeled with the knowledge of the illumination direction. Thereafter, each shadow region is handled separately and the initial building regions are identified by iterative graph-cuts designed in two-label partitioning. The second stage of the framework automatically classifies the image into four classes: building, shadow, vegetation, and others. In this step, the previously labeled building regions as well as the shadow and vegetation areas are involved in a four-label graph optimization performed on the entire image domain to achieve the unsupervised classification result. The final stage aims to extend this classification to five classes, including the road class. For that purpose, we extract the regions that might belong to road segments and utilize that information in a final graph optimization. This final stage eventually characterizes the regions belonging to buildings and roads. Experiments performed on twelve test images selected from GeoEye-1 VHR datasets show that the presented approach has the ability to extract the regions belonging to buildings and roads in a single graph theory framework.

Keywords

Building Detection, Road Detection, Fuzzy Landscapes, Multi-label Graph Partitioning, VHR Satellite Imagery

** Hakemli değerlendirme sürecinden geçerek, Jeodezi ve Jeoinformasyon Dergisi'nde yayına kabul edilen ve asıl yazı dili İngilizce olan "Automated Detection of Buildings and Roads in Urban Areas from VHR Satellite Images" başlıklı eserin Türkçe diline çevirisidir.

Çeviren; Ali Özgün Ok.

* Sorumlu Yazar:

E-Posta: ozgunok@nevsehir.edu.tr

1. Giriş

Çok yüksek çözünürlüklü uydu görüntülerinde bir kentsel alanın sınırları içerisinde yer alan insan yapımı nesnelere arasında en önemli iki sınıfı binalar ve yollar temsil etmektedir. Bunun temel nedeni ise insan nüfusunun büyük çoğunluğunun kent merkezlerinde ve banliyölerde yaşamasıdır. 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. 40 yılı aşkın bir süredir çok sayıda araştırmacı bina ve yol nesnelere tespitine yönelik önemli sayıda araştırma gerçekleştirmiş ve bu konuda çok sayıda çalışma yapılmıştır. Bina nesnelere ait geçmiş çalışmaları kapsamlı bir şekilde sınıflayan ve özetleyen inceleme makaleleri Mayer (1999), Baltavias (2004), Brenner (2005), ve Haala ve Kada (2010) tarafından yayımlanmıştır. Buna ek olarak, Baumgartner vd. (1997) ve Mena (2003) inceleme makaleleri yol tespiti konusu ile ilgili literatürü özetlemiş ve tanımlamıştır. Bu çalışmanın amacı çok yüksek çözünürlüklü tek bir uydu görüntüsünden bina ve yol nesnelere ait olan bölgelerin otomatik olarak belirlenmesine olanak sağlayacak çizge-tabanlı bir yöntem tasarlamak ve geliştirmektir. Bu nedenle literatür taraması kapsamında sadece tek bir optik uydu görüntüsünden otomatik olarak bina ve/veya yol nesnelere 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 yararlanmış (örn., Lin ve Nevatia, 1998; Katartzis ve Sahli, 2008; Akçay ve Aksoy, 2010). Tek bir görüntüye yönelik olarak gerçekleştirilen diğer çalışmalarda görüntülerdeki çokbant 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 (örn., Karantzalos ve Paragios, 2009), Markov Rastgele Alanları (MRA) (e.g. Katartzis ve Sahli, 2008), çizge-tabanlı (örn., Akçay and Aksoy, 2010; Izadi and Saeedi, 2012), ve kernel-tabanlı (Sirmacek ve Ünsalan, 2011) yaklaşımlarda aynı zamanda halen süregelen araştırma konuları arasındadır. Güncel yapılan iki çalışmada, binaların zor çevresel koşullarda 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 kurula dayalı sistemler ve bilgiye dayalı yaklaşımlar popülerdir. Çeşitli çalışmalarda yol alanlarının belirlenmesi probleminin 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 amacıyla 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 bölümlerine 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 amacıyla 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 çalışmalar 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 nesnelere 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 çalışma çok yüksek çözünürlüklü optik uydu

görüntülerinden bina ve yol nesnelere ait olan bölgelerin otomatik olarak belirlenmesine olanak sağlayacak bir yöntem sunmaktadır. Yöntem temel olarak üç ana aşamadan oluşmaktadır. Birinci aşama sadece bina bölgeleriyle ilgili bilgilerin elde edilmesini amaçlamıştır. Bu nedenle gölge bilgisinde yararlanılmış ve bina nesnelere ait gölgeleri arasında var olan mekânsal ilişki görüntü düzleminde modellenmiştir. Ayrıca, bina olmayan nesnelere yönelik muhtemel ilişkiler sistematik bir yöntem kullanılarak elelenmiştir. Devamında, bina alanları iki etiketli olarak gerçekleştirilen (bina ve diğerleri) ve her gölge nesnesi için ayrı ayrı olarak uygulanan ve ilgi alanlarında (ROI) gerçekleştirilen 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 bina, gölge ve bitki örtüsüne ait bölgeler ve herhangi bir etiket almamış olan diğer alanlar tüm görüntü üzerinde gerçekleştirilen dört etiketli bir çizge-tabanlı optimizasyon işlemine tabi tutulmuştur. Üçüncü aşama ise bina ve yol nesnelere ait nihai bölgelerin belirlenmesini amaçlamıştır. 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 (bina, gölge, bitki, yol ve diğer) ile nihai çizge-tabanlı optimizasyon gerçekleştirilmiştir. Bu son aşama bütün görüntüyü otomatik olarak beş sınıfa ayırmakta ve bu sayede görüntüye ait bina ve yol bölgeleri elde edilmektedir. Geliştirilen yöntemin işlem adımları aşağıdaki bölümlerde 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. Belirtilen bu iki çalışma sadece bina

nesnelere yönelik olarak tasarlanmıştır, oysa bu çalışmanın özgün değeri bina ve yol sınıflarının tek bir çok-sınıflı çizge-tabanlı optimizasyon yönteminde ele alınmasından ileri gelmektedir.

Çalışmanın işlem adımları metnin ilerleyen bölümlerinde açıklanmaktadır. Buna göre; Bölüm 2’de önerilen 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. Önerilen Yöntem

2.1. Görüntü ve Üst veri

Bu çalışmada önerilen yaklaşım tek bir keskinleştirilmiş çok-bantlı (M, Y, K ve YKÖ) ortogörüntüyü kullanmaktadır. Bu çalışmada kullanılan tüm GeoEye-1 test görüntüleri bir pankromatik (50 cm yer örnekleme aralığı - YÖA) ve 4-bantlı (M, Y, K, YKÖ) (2 m YÖA) 11 bit radyometrik çözünürlüğe sahip görüntülerden oluşmaktadır. Ayrıca görüntünün çekim zamanına ait güneş açıları (azimuth ve zenith) ile ilgili bilgiler üst veri (metadata) olarak görüntüye eklenmiştir. Keskinleştirilmiş görüntüleri oluşturmak için açık kaynak kodlu görüntü işleme ve uzaktan algılama yazılımı olan Orfeo’da (OTB, 2012) bulunan Smoothing Filter-based Intensity Modulation (SFIM) yönteminden (Liu, 2000) yararlanılmıştır.

2.2. Bitki ve Gölge Alanlarının Tespit Edilmesi

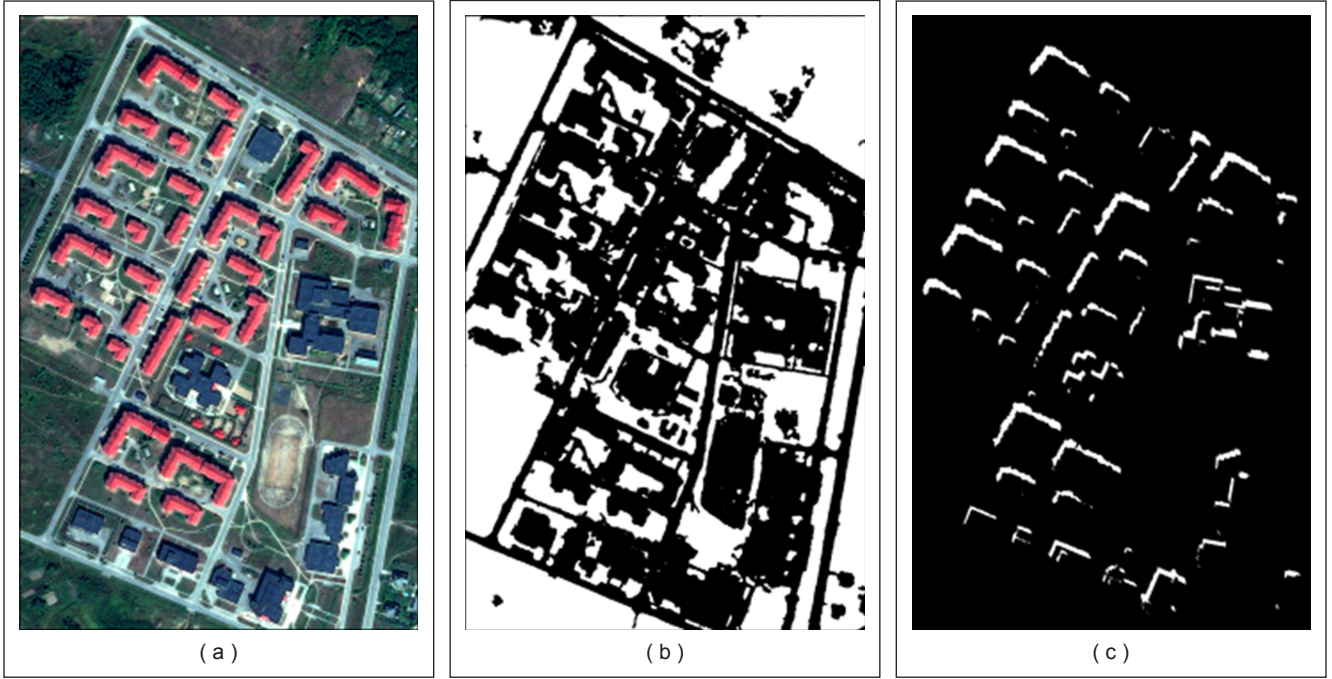
Bitki örtüsünün bulunduğu alanları tespit edebilmek amacıyla Normalize Diferansiyel Bitki İndeksinden (NDVI) yararlanılmıştır. Bu indeks sağlıklı bitki örtüsünün gözlemlendiği yerlerde yüksek değerler üretmek amacıyla tasarlanmış olup bu yüksek değerler genellikle bitki örtüsü bulunan alanları göstermektedir. Bu çalışmada bitki örtüsü maskesini (M_v) otomatik olarak hesaplayabilmek amacıyla Otsu metoduna (Otsu, 1975) dayanan histogram eşikleme metodu kullanılmıştır (Şekil 2b). 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 yalnızca renk birleşiminden geçilmektedir (YKÖ, K, Y). Gölge alanlarını otomatik belirlemek için tıpkı bitki örtüsü tespitinde de faydalandığı üzere Otsu’nun metodu uygulanmıştır. Devamında bitki örtüsünün bulunduğu alanlar gölge maskesi (M_s) elde etmek amacıyla çıkarılmıştır. Bu çalışmada gölge maskesinin filtrelenmesi ve görece kısa nesnelere ait gölge alanlarının temizlenmesi amacıyla Ok (2013)’te önerilen kısıtlı son işleme yaklaşımı kullanılmış ve temizlenmiş gölge maskesi (M_{ps}) elde edilmiştir (Şekil 2c).

2.3. 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



Şekil 1: Önerilen yöntem özeti.



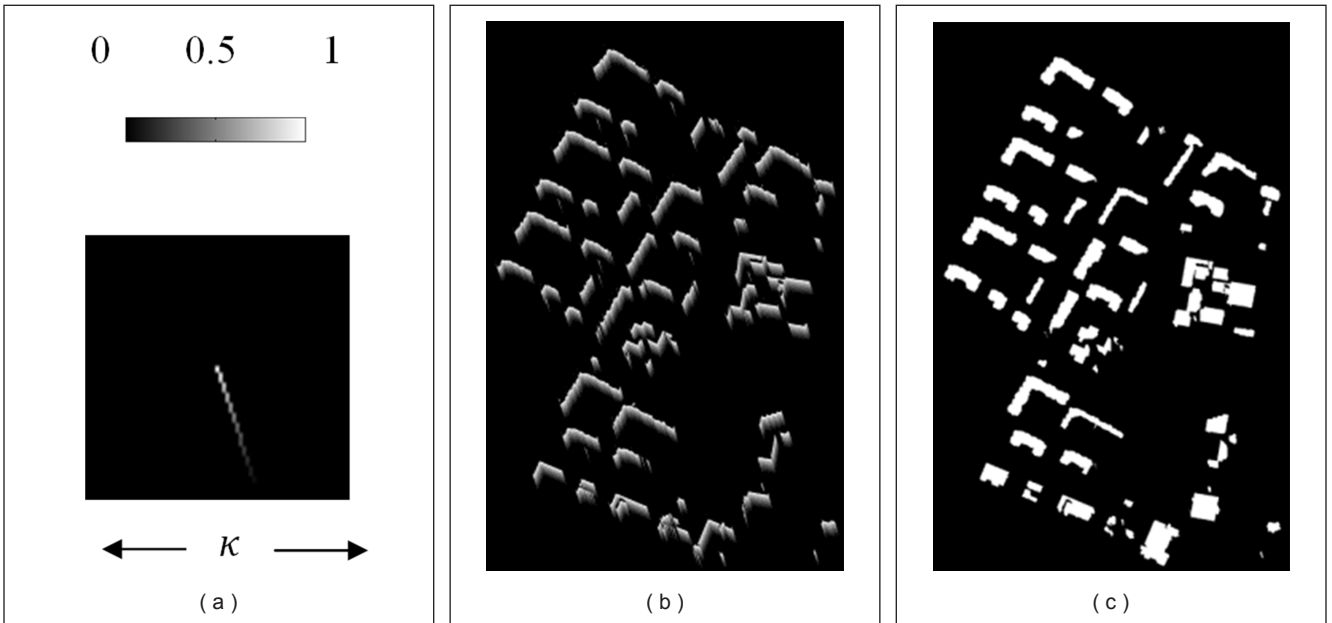
Şekil 2: (a) Keskinleştirilmiş GeoEye-1 görüntüsü (KYM), (b) bitki örtüsü maskesi (M_v), (c) temizlenmiş gölge maskesi (M_{ps}).

yapıtışı elemanı $v_{L,\alpha,\sigma,\kappa}$, verildiğinde bir görüntüdeki gölge nesnesinin etrafında verilen α yönündeki bölge $\beta_\alpha(B)$ aşağıdaki şekilde tanımlanmaktadır:

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

Eş. 1'de 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 genişleme 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 (Şekil 3b). Eş. 1'de kullanılan yapıtışı elemanı $v_{L,\alpha,\sigma,\kappa}$ (Şekil 3a) birbirinden farklı iki yapıtışı elemanının birleştirilmesi (*) suretiyle oluşturulmuştur: $v_{L,\alpha,\sigma,\kappa} = v_{L,\kappa,\alpha} * v_{\sigma,\kappa}$. Burada $v_{\sigma,\kappa}$ kernel boyutu κ olan yön bağımsız ve olasılık değerleri 0 ile 1 arasında içeren bir yapıtışı elemanı, $v_{L,\kappa,\alpha}$ ise sadece α yönünde 0 ve 1 ikili değeri içeren yapılandırma elemanı tanımlamaktadır. Yine aynı formülde bulunan L bir çizgiyi ve α ise çizginin yönlendirildiği açı değerini betimlemektedir. Eş. 1 ile elde edilen bölgeler görüntü üzerindeki tüm gölge alanları için üretilmektedir (Şekil 2b).



Şekil 3: (a) Yapıtışı elemanı $v_{L,\alpha,\sigma,\kappa}$, (b) Şekil 2c'deki gölge maskesi kullanılarak üretilen olasılık haritası ve (c) Aşama 1 sonucunda elde edilen bina alanları.

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

Bu aşamada bina tespit işlemi her bina alanını arka plandan (bina ve diğerleri) ayıracak şekilde iki sınıflı bölütleme problemi olarak ele alınmıştır. Bu nedenle görüntüdeki bina sınıfı sadece binalara ait olan pikselleri, bina-değil sınıfı ise bina alanlarına ait olmayan pikselleri tanımlamaktadır. Bu ikili sınıflandırma problemi çözmek amacıyla aşağıda enerji denklemi verilen yinelemeli iki etiketli çizge-kesme optimizasyonundan (GrabCut) (Rother vd., 2004; Boykov ve Kolmogorov, 2004) yararlanılmıştır:

$$E(f) = \sum_{n \in P} -D_n(f_n) + \gamma_1 \sum_{(m,n) \in N} e^{-\beta \|z_m - z_n\|^2} \quad (2)$$

Eş. 2'de, $D_n(f_n)$ terimi sonucu karışım modellerine dayanan ve gözlenen z piksel değerleri dikkate alınarak her n pikseli için hesaplanan etiket tercihini (ön plan/arka plan), N parametresi 8-komşuluk ile hesaplanan komşu piksel çift setlerini, β ve γ_1 parametreleri ise düzleştirme seviyesini tanımlayan katsayıları belirtmektedir. Optimizasyonu tamamlamak ve tüm piksellerin etiket değerlerini tahmin etmek için ise minimum-kesme/maksimum-akış algoritması uygulanmıştır.


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/bina (T_F) ve arka plana/bina-değil (T_B) karşılık gelen pikseller gölge alanları ve gölgeden üretilen bölgeler-

in kullanılmasıyla otomatik olarak etiketlenmektedir. 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.

2.5. 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 3c). 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 (M_P s) ile birlikte dört sınıfa ayrılabilir. Öncelikle bulunan *bina*, *bitki* ve *gölge* alanları ilk üç sınıfa ait etiketleri belirlemektedir. Devamında bu üç sınıfa dahil olmayan bölgeler dördüncü bir sınıf olan *diğer* şeklinde tanımlanmıştır (Şekil 4a).

Bu aşamada Ok (2013) tarafından önerilen yaklaşım uygulanmıştır. Bu yaklaşım dört etiketli bir çizge-kesme optimizasyonu geliştirmiştir. Bir görüntüdeki tüm pikseller $z = (z_1, z_2, \dots, z_N)$ ve tüm olası etiketler $L \in \{1, \dots, l\}$ olarak tanımlandığında (ki burada $l = 4$ 'dür), bu aşamada amaç L 'de yer alan etiketleri tüm z verilerine optimum olacak şekilde sınıflamaktır. II. aşamanın başında her bir pikselin



Şekil 4: (a) Aşama II girdisi, (b) doğrulanmış bina alanları ve (c) aşama II çıktısı. Beyaz, yeşil, siyah ve gri renklerle bina, bitki örtüsü, gölge ve diğer sınıflara ait alanları belirtmektedir.

(z_i) bir ilk etiket değeri (α_n) mevcut olup bu değer (α_n) $\in \{1,2,3,4\}$ her bir sınıf etiketine (L) tekabül etmektedir. Sınıflama için bu çalışmada Eş. 2’de verilen Gibbs enerji fonksiyonu kullanılmış 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 yaklaşımın detayları ([Boykov vd., 2001](#)) çalışmasında açıklanmıştır. Yaklaşım, çok-etiketli enerji fonksiyonlarının optimizasyonunda global minimum değerine ulaşmasa da, o değere yakın sonuçlar ürettiği kanıtlanmıştır. Burada α -genişleme yaklaşımı kısaca tanımlanmıştır ve detaylar için [Boykov et al. \(2001\)](#) çalışmasına bakılabilir. Simgesel olarak α belirli bir sınıf etiketini, f ve g ise z görüntü verisinden sınıf etiketlerinden L ’ye giden iki farklı işlemeyi belirtsin. n simgesi z verisindeki bir pikseli temsil ederken eğer $g_n \neq \alpha$ şartı $g_n = f_n$ ’i tanımlıyorsa g işlemesi f ’den gerçekleşen α -genişlemesi olarak tanımlanır. Bu tanımlamayla, f ’den g ’ye giderken α etiketi alan piksel sayısı artmış olur. Yöntem sabit veya rastgele olacak şekilde L ’deki tüm etiketler için döngüler gerçekleştirmekte ve genişleme hareketlerine göre tanımlanan bir enerji fonksiyonunun yerel minimumu olacak şekilde görüntü verisi z ’den L ’deki tüm etiketlere eşlemeleri bulmayı hedeflemektedir. Yöntemin sonlu sayıda döngü sonrasında sonlanacağı kesindir ve L ’deki tüm sınıflar için başka düşük enerjili bir α -genişleme adımı kalmayınca sonlanmaktadır.

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 ([Şekil 3c](#)) kullanılarak bina bölgelerini daha doğru bir şekilde belirlemek mümkün olabilmektedir ([Şekil 4b](#)). Son olarak gölge bilgisi ile doğrulanamayan tüm bina bölgeleri diğer sınıfına dâhil edilmektedir ([Şekil 4c](#)).

2.6. 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 5a](#)). 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 yapıları nedeniyle). İşte bu sebeplerden dolayı bu aşamada hedef ikinci aşamadan elde edilen bilgilerin kullanılması suretiyle yollara ait olan bölgeleri ayırt etmektir. Ancak [Şekil 5a](#)’da görüldüğü üzere diğer sınıfına ait olan bölgeler oldukça karmaşık yapıda olup yol alanlarını basit bir son-işleme ile bulmak mümkün olamamaktadır. Bu nedenle bu aşamada, yolların ayrı bir sınıf halinde belirleneceği 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 5b](#)). Bu son optimizasyon aşamasında toplam beş sınıfı kullanılmaktadır. Bu sınıflar bina, yol, bitki örtüsü, gölge ve diğerleri şeklindedir. Son işleme kısmında ise optimizasyon sonucundan ([Şekil 5c](#)) bina ve yol olarak etiketlenen bölgeler çekilmiş ve nihai bina sınıfı sonuçları için son olarak ikinci aşamanın sonunda uygulanan gölge kontrolü tekrardan uygulanmıştır.

3. Sonuçlar ve Tartışma

Önerilen yaklaşımın değerlendirilmesi amacıyla farklı çekim koşullarının yanı sıra kentsel alan ve bina karakteristikleri açısından da farklılıklar gösteren on iki 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 F1 skoru performans

ölçütleri kullanılmıştır:

$$\text{Kesinlik} = \frac{|TP|}{|TP| + |FP|} \quad (3)$$

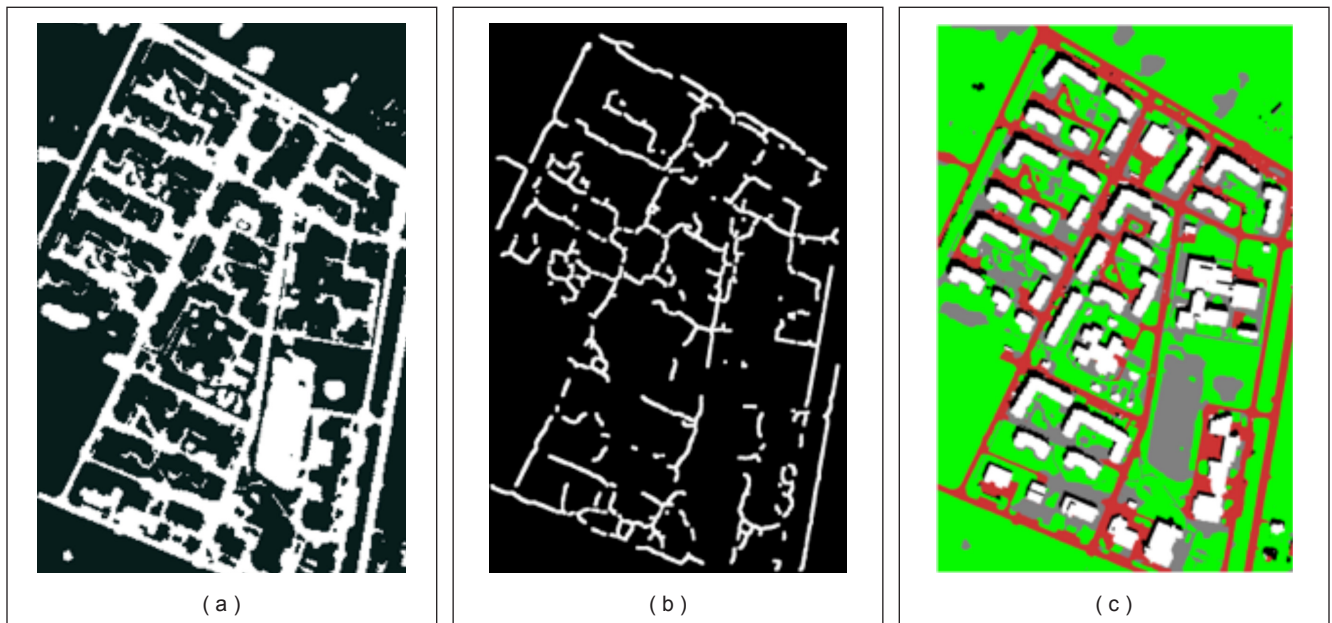
$$\text{Geri getirme} = \frac{|TP|}{|TP| + |FN|} \quad (4)$$

$$F_1 = \frac{2 * \text{kesinlik} * \text{geri getirme}}{\text{kesinlik} + \text{geri getirme}} \quad (5)$$

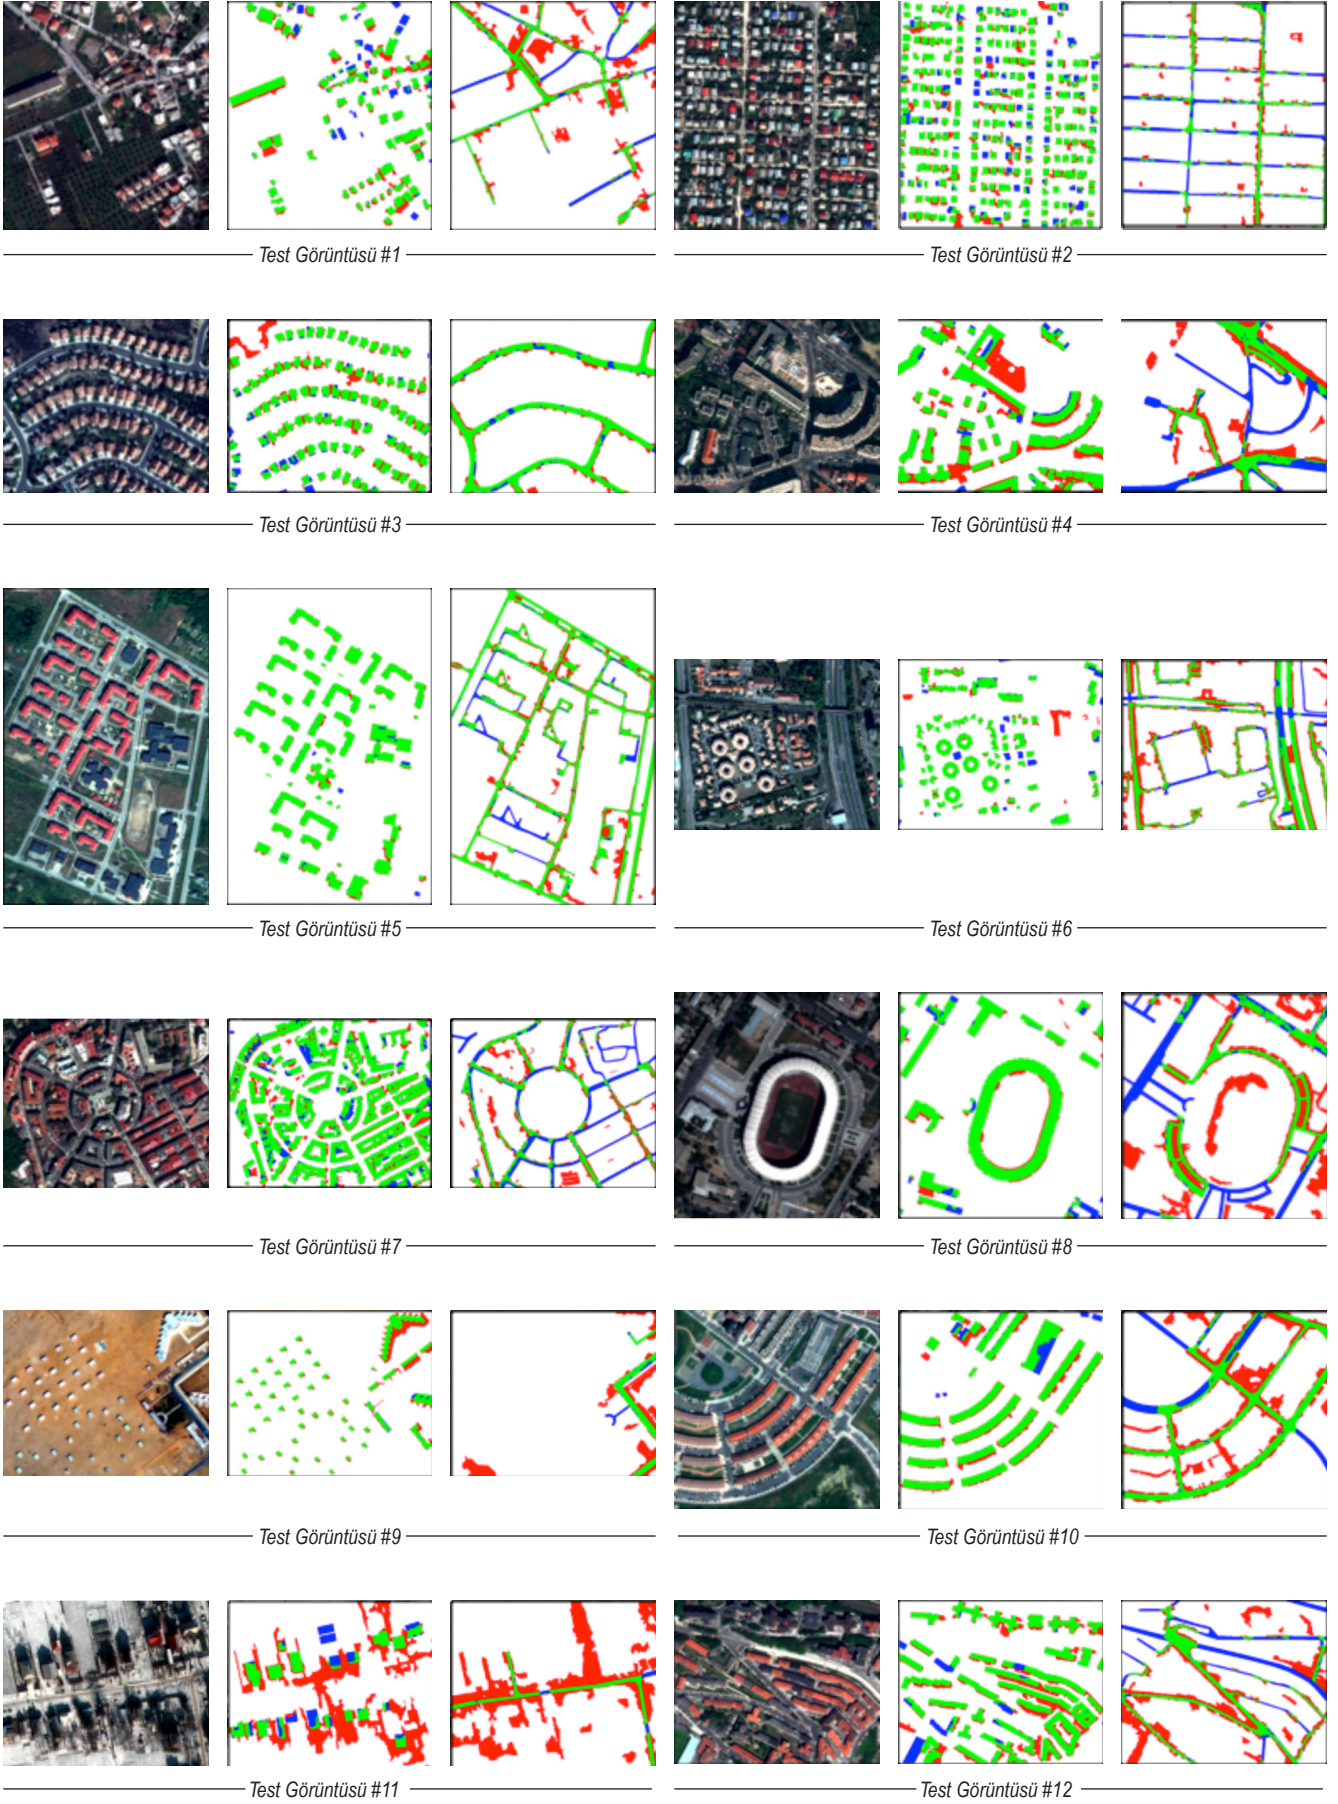
Eş. 3-5’de, *TP* doğru pozitifleri, *FP* yanlış pozitifleri ve *FN* yanlış negatifleri tanımlamaktadır. $|\cdot|$ operatörü her farklı kategoriye atanmış olan piksel sayısını belirtmekte ve F_1 -skoru Kesinlik ve Geri getirme değerlerinden tek bir performans değeri üretmektedir. Önerilen yaklaşımın obje-tabanlı performansı yine Eş. 3-5’de verilen ölçütlerle yapılabilmektedir. Bu çalışmada bir bina çıktısı referans veri ile en az %60 oranında örtüşüyorsa (Aksoy et al., 2012; Ok et al., 2013; Ok, 2013) *TP* olarak etiketlenmektedir. Bununla birlikte, eğer bina çıktısı referans verideki hiçbir bina nesnesi ile örtüşmüyorsa *FP* olarak ve eğer bina çıktısı referans verideki nesnelere sınırlı oranda (< 60%) örtüşüyorsa *FN* olarak etiketlenmektedir. Fakat genel olarak bu tanımlanan obje-tabanlı değerlendirme yol sınıfı için anlamlı sonuçlar üretmeyebilir çünkü yol alanları sonuçta birleşik olarak tek bir yol nesnesi olarak bulunabilmektedir. Bu nedenle, yol tespiti konusunda bu çalışmada obje-tabanlı sonuçlar hesaplanmamıştır. Önerilen yöntem herhangi bir operatör desteği olmaksızın çalışabildiğinden yöntemin ihtiyacı olan parametreler tanımlandığında hızlı bir şekilde kullanılabilir. Birinci ve ikinci aşama için gereksinim duyulan tüm 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 6’da sunulmuştur. Bu sonuçlara göre geliştirilen yaklaşım hem binaların hem de yolların tespit edilmesi için etkin bir yöntem olarak görünmektedir. Bina alanları, örneğin çatı rengi, doku, 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 Tablo 1 ve 2’de verilen sayısal sonuçlar bu yorumları desteklemektedir. Bina için piksel-tabanlı hesaplanan genel kesinlik ve geri getirme oranları sırasıyla %81.3 ve %89.7’dir. Yine bina sınıfı için on iki test görüntüsü için hesaplanan F_1 skoru yaklaşık olarak %85 civarındadır. Buna ek olarak obje-tabanlı hesaplanan genel kesinlik ve geri getirme oranları sırasıyla %96.9 ve %84.9’dur. On iki test alanı için hesaplanan obje-tabanlı F_1 skoru ise %90.5’dir. Öte yandan, yol sınıfı için genel kesinlik ve geri getirme oranları sırasıyla %55.1 ve %68.8 olarak hesaplanmıştır. Bu ise yaklaşık olarak %61.2’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 6’da 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 anlaşılabilirdiği üzere binaların iyi bilinen karmaşık karakteristiklerinden (örneğin çatı rengi, doku, şekil, boyut ve yönelim gibi) 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. En düşük kesinlik oranı (%25.9) #11 numaralı test görüntüsü için elde edilmiştir.



Şekil 5: (a) Diğer sınıfa ait alanlar, (b) yol sınıfı girdisi ve (c) aşama III çıktısı. Beyaz, kırmızı, yeşil, siyah ve gri renkleri sırasıyla bina, yol, bitki örtüsü, gölge ve diğer sınıfa ait alanları belirtmektedir.



Şekil 6: Test veri seti (KYM) (solda), tespit edilen bina alanları (merkez) ve tespit edilen yol alanları (sağda). Yeşil, kırmızı ve mavi renkler sırasıyla doğru-pozitif, yanlış-pozitif ve yanlış-negatif alanları göstermektedir.

Tablo 1. Önerilen yaklaşımın bina tespit sonuçları.

Test Görüntüsü	Performans (%)					
	Piksel - tabanlı			Obje - tabanlı		
	Kesinlik	Geri Getirme	F_1 - Skoru	Kesinlik	Geri Getirme	F_1 - Skoru
#1	74.0	81.8	77.7	100	76.0	86.4
#2	77.4	82.2	79.7	99.2	81.0	89.2
#3	76.9	89.3	82.6	97.9	90.3	93.9
#4	67.1	92.9	77.9	97.6	93.0	95.2
#5	92.8	96.5	94.6	100	94.9	97.4
#6	84.8	87.7	86.2	91.4	80.0	85.3
#7	87.1	90.4	88.7	88.9	96.6	92.6
#8	89.9	91.5	90.7	84.2	72.7	78.1
#9	65.2	97.3	78.1	100	100	100
#10	83.0	92.1	87.3	95.0	82.6	88.4
#11	25.9	69.3	37.7	94.1	69.6	80.0
#12	74.9	89.2	81.4	97.1	86.8	91.7
Toplam	81.3	89.7	85.3	96.9	84.9	90.5

Tablo 2. Önerilen yaklaşımın yol tespit sonuçları.

Test Görüntüsü	Performans (%)		
	Kesinlik	Geri Getirme	F_1 - Skoru
#1	41.6	69.1	51.9
#2	62.8	52.8	57.4
#3	84.3	91.3	87.7
#4	50.0	50.8	50.4
#5	72.6	87.1	79.2
#6	58.7	77.7	66.9
#7	56.9	52.1	54.4
#8	39.8	53.0	45.4
#9	35.8	86.2	50.5
#10	53.3	77.2	63.1
#11	14.2	89.0	24.4
#12	38.9	56.0	45.9
Toplam	55.1	68.8	61.2

Bu görüntü çok alçak güneş yükseklik açısıyla (21.54°) kış döneminde çekilmiştir. Bu nedenle, görüntüdeki alanlar neredeyse tamamen karla kaplanmış ve alçak güneş yükseklik açısı bina çatılarında (özellikle beşik çatı şeklindeki binalarda) tespiti zorlayıcı ciddi gölge etkilerine neden olmaktadır. Bu nedenle, en düşük geri getirme oranı da yine bu görüntüye (#11) aittir. Bunun yanı sıra bazı durumlarda önerilen yöntem bina sınırlarını fazla bulabilmektedir ve bu sorunla ilgili tipik örnekler #9, #4 ve #12 numaralı test görüntülerinde görülebilmektedir. Bu sonuç iki temel nedene dayanmaktadır. İlk olarak, bazı binaların sınırları çevresindeki alan ile yeterince keskin bir renk geçişi oluşturmamaktadır. #9 numaralı test görüntüsünde yer alan çöl alanı buna güzel bir

örnektir. İkinci olarak, beşik çatıya sahip binaların bir kısmı yanlışlıkla gölge olarak tespit edilebilmektedir (örn., #4 numaralı test görüntüsünde belirgin olan geniş yanlış saptama). Maalesef bu görüntüde aşırı saptamanın olduğu 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 (örn., #3 numaralı test görüntüsünün sol üst köşesinde görülen iki hatalı bölge). 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 #6 numaralı test alanında görülmektedir. 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. Test alanlarında farklı bina şekilleri (dikdörtgen (örn., #1, #9), L-şeklinde (örn., #5), altıgen (örn., #6), eliptik (örn., #8), yay-şeklinde (örn., #4, #10) bulunmakta ve bunların büyük çoğunluğu başarılı bir şekilde tespit edilmiştir. Tahmin edileceği üzere, yöntem bina gölgelerinin tamamen görülebilir olduğu ve başka bir nesne ile kapatılmadığı durumlarda (#5, #8) en iyi performansı üretmektedir.

Şekil 6'dan elde edilen sonuçlar geliştirilen yaklaşımın yol alanlarını diğer nesnelere tarafından (örn., bina veya ağaç

gibi) kapatılmaması durumunda tespit edebilme yeteneğine sahip olduğunu göstermektedir. Bir diğer ana problem ise bu nesnelere (#4 ve #7) oluşturduğu gölgeler nedeniyle ortaya çıkmaktadır. Yoğun binaların bulunduğu kentsel alanlarda yol tespit performansı özellikle görüntünün çekim anına ait güneş açılarının (azimuth ve zenith) bağlı bulunmaktadır. Bu nedenle görüntü çekiminde güneş açılarının uygun olmadığı durumlarda (örn., alçak güneş yükseklik açısı) yoğun bir kentsel alandaki yol alanlarının tamamını belirlemek mümkün olmayacaktır. Yine de önerilen yöntem #4 ve #7 numaralı test görüntülerinde açık olarak görünen yol kısımlarının çoğunu yakalamıştır. Önerilen yaklaşım, belirli bir yol tipinin, örn., asfalt (#3 ve #5), bulunduğu durumlarda en iyi sonucu vermektedir. Fakat bazı belirli yol tiplerine (örn., #12 numaralı görüntüdeki beyaz yol gibi) ait bilgi otomatik olarak toplanamadığında bu alanları doğru bir şekilde etiketlemek mümkün olamamaktadır. Daha önemlisi, eğer yolun rengi açık alanlara (örn., #11) oldukça benziyorsa istenmeyen yanlış pozitif alanlar ortaya çıkmaktadır. Yol alanlarının belirlenmesine yönelik vurgulanması gereken bir diğer önemli husus ise çizge-tabanlı optimizasyon sırasında uygulanan düzgünlük varsayımdır. 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 (yol genişliği aniden değişmez) yararlanmakta olup bina ve yol alanlarının tespiti için operatör tarafından toplanan herhangi bir bilgi kullanmamaktadır. Bu nedenle geliştirilen yaklaşım, bina ve yolların bulunması için özgün bir davranış sergilemekte ve karmaşık alanlarda başarılı sonuçlar üretmektedir.

4. Sonuç

Bu çalışmada çok yüksek çözünürlüklü 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 on iki adet test görüntüsü üzerinde yapılan değerlendirmeler, geliştirilen yaklaşımın neticesinde bina ve yol alanlarının ortak bir şekilde belirlenebilme potansiyeline sahip olduğunu göstermektedir. Sonuçlar aynı zamanda önerilen yaklaşımın herhangi bir ön bilgi kullanmadan bina ve yollara ait alanlar hakkında önemli oranda bilgiyi üretebildiğini kanıtlamıştır.

İlerleyen çalışmalarda, yol sınıfı için otomatik olarak bilgilerin toplandığı üçüncü aşama iyileştirilecektir. Kentsel bir alan düşünüldüğünde en önemli hedeflerden birisi büyük köprü nesnelere bina alanlarından ayırt etmektir. Böylece bina ve köprü nesnelere arasında mantıksal bir ayrımın yapılmasını sağlayabilecek bir yöntem geliştirilebilecektir. Güncel yapılan çalışmalar yüksek komşuluklu MRA'ların yollara ait olan bölgeleri daha başarılı bir 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

Yazar bu çalışmada kullanılan test verilerini sağlayan HAVELSAN A.Ş.'ye teşekkürlerini sunar. Ayrıca yazar faydalı yorumlarından dolayı hakemlere de teşekkürlerini iletmektedir.

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., Yalın 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.
- Baltsavias E.P., (2004), *Object extraction and revision by image analysis using existing geodata and knowledge: current status and steps towards operational systems*. ISPRS Journal of Photogrammetry and Remote Sensing, 58(3-4), 129-151.
- Baumgartner A., Steger C., Mayer H., Eckstein W., (1997), *Multiresolution, Semantic Objects, and Context for Road Extraction*. In: Semantic Modeling for the Acquisition of Topographic Information From Images and Maps, Cambridge, Birkhauser-Verlag, pp.140-156.
- 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.
- Brenner C., (2005), *Building reconstruction from images and laser scanning*. International Journal of Applied Earth Observation and Geoinformation, 6(3-4), 187-198.
- 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.
- Haala N., Kada M., (2010), *An update on automatic 3D building reconstruction*. ISPRS Journal of Photogrammetry and Remote Sensing, 65(6), 570-580.
- 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*. In: *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., Saedi P., (2012), *Three-Dimensional polygonal building model estimation from single satellite images*. IEEE Transactions on Geoscience and Remote Sensing, 50(6), 2254-2272.
- Karantzas 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.
- Liu J.G., (2000), *Smoothing filter-based intensity modulation: A spectral preserve image fusion technique for improving spatial details*. International Journal of Remote Sensing, 21(18), 3461-3472.
- Mayer H., (1999), *Automatic object extraction from aerial imagery-A survey focusing on buildings*. Computer Vision and Image Understanding, 74(2), 138-149.
- Mayer H., Hinz S., Bacher U., Baltasavias 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., (2003), *State of the art on automatic road extraction for GIS update: a novel classification*. Pattern Recognition Letters, 24(16), 3037-3058.
- 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(2013), 21-40.
- OTB, (2012), Orpheo Toolbox, <http://www.orfeo-toolbox.org/doxygen/>, [Accessed 06 March 2012].
- 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., Özyay 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*, In: 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.