

Yüksek Çözünürlüklü Multispektral Uydu Görüntülerinde Kuvvetlendirilmiş Sınıflandırıcılar Kullanılarak Otomatik Yol Çıkarımı

Road Extraction from Multispectral Satellite Images Using Boosted Classifiers

Umut ÇİNAR¹, Ersin KARAMAN², Ekin GEDİK³, Yasemin YARDIMCI¹

¹Bilişim Sistemleri Bölümü
Orta Doğu Teknik Üniversitesi
ucinar@metu.edu.tr, yyardim@metu.edu.tr

²Yönetim Bilişim Sistemleri Bölümü
Atatürk Üniversitesi
ersinkaraman@atauni.edu.tr

³Bilgisayar Mühendisliği Bölümü
Orta Doğu Teknik Üniversitesi
gekin@metu.edu.tr

Özet

Bu çalışmada yüksek çözünürlüklü multispektral uydu görüntülerinden karayolu çıkarımı için yeni bir yöntem önerilmiştir. Önerilen yöntem, literatürde genellikle su ve bitki örtüsünün sınıflandırılması için kullanılan ve spektral bantların oranlanmasıyla elde edilen indisler ile birlikte bölütleme sonuçları üzerinden elde edilen bölütlere ait yapısal özellikleri öznitelik olarak kullanmakta ve ADABOOST gözetimli bir öğrenme algoritmasını bu öznitelikler ile eğitmektedir. Algoritma çeşitli uydu görüntülerinde denenmiş, yol çıkarımında başarılı olduğu gözlemlenmiştir.

Anahtar Kelimeler: Örüntü Tanıma, Uzaktan Algılama, Uydu Görüntüleri, Yol Çıkarımı.

Abstract

In this study, a new method for extracting road mask from high resolution multispectral satellite images is proposed. Proposed method uses indices which are generally utilized for water or vegetation detection in the literature with the structural properties of segments generated by segmentation procedure as features and trains ADABOOST supervised learning algorithm with them. The proposed method is tried on different satellite images and it is observed that the proposed method which is developed using Adaboost learning algorithm is succesful at extracting road networks from satellite images.

Keywords: Pattern Recognition, Remote Sensing, Satellite Images, Road Extraction.

1. Giriş

Karayolu haritaları navigasyon desteği, şehir-bölge planlama uygulamaları, harita güncelleme, acil durum yönetimi, askeri karar destek sistemleri gibi uygulamalarda önem taşımaktadır. Bu bağlamda en güncel veri otomatik yol tanıma sistemleri ile uydu görüntülerinden temin edilebilmektedir. Uydu görüntülerinden karayolu çıkarımı üzerine birçok çalışma mevcuttur. Ancak, uydu görüntülerinin gerek mekânsal gerek spektral çözünürlüklerinin giderek iyileşmesi yol çıkarımı çalışmalarına yeni bir boyut kazandırmıştır. Otomatik yol çıkarımı üzerine yapılmış birçok çalışma incelendiğinde, bu çalışmaların temel imge işleme metotları, bilgi tabanlı yaklaşımlar, frekans temelli yöntemler, bölütleme ve kümeleme gibi literatürdeki birçok metottan yararlandığı görülmüştür.[1-7] Ayrıca literatürdeki birçok çalışmanın olası yolları bulmak için gözetimli öğrenme metotlarını kullandığı ve yolların spektral özelliklerinin öznitelik olarak alındığı gözlemlenmiştir [8-9].

Yolların spektral özelliklerinin görüntünün alındığı uyduya ve yolun malzeme tipine(asfalt, beton, toprak) göre değişiklik gösterdiği bilinmektedir. Bu sebeplerden, sadece spektral değerlerin kullanıldığı gözetimli öğrenme metotları, farklı uydulardan alınan görüntülerde başarılı sonuçlar verememektedir. Bu problemin çözümü için kullanılacak özniteliklerin farklı görüntülerde de çalışacak şekilde kararlı olması gerekmektedir. Bu açıdan, SAVI ve NDVI gibi bitki örtüsü çıkarımı için geliştirilen spektral indekslerin öznitelik olarak kullanılması imge tipine bağımlılığı azaltmaktadır.

Bu ve benzeri indisler yol spektral niteliklerini tanımlar olmasa da, spektral değerlerin oranları kullanıldığı için benzer tipteki yollar, farklı imgelerde de benzer değerler vermektedir. Ayrıca bölütleme işleminden sonra bölütlerin yapısal özelliklerinin incelenerek yol bölgelerinin çıkarımı literatürde kullanılan bir diğer yöntemdir [7]. Bu yapısal özelliklerin öznelik olarak kullanılmasıyla da yolların sadece spektral karakteristikleri göz önünde bulundurulmamakta, yapısal özellikleri de göz önünde bulundurulmaktadır. Bu sayede farklı tipteki yolların da bulunabilmesi amaçlanmaktadır.

2. Yöntem

2.1. Veri


Bu çalışmada, uydu görüntülerindeki yol olan bölgeleri otomatik olarak sınıflandırmak için 1-metre (0.82) pankromatik ve 4-metre multispektral çözünürlüklü IKONOS ve 0.5-metre (0.42) pankromatik ve 2-metre (1.65) multispektral çözünürlüklü GEOEYE uydu görüntüleri kullanılmıştır. Multispektral bantlar sırasıyla, Mavi, Yeşil, Kırmızı ve Yakın kızılötisedir. İmgelerdeki yansıtma değerleri 11 bit ile ifade edilmektedir. İmgeler üzerinde görüntü keskinleştirme (pan-sharpen) işlemi yapılmıştır.

2.2. Algoritma

Bu çalışmada önerilen yöntem, yüksek çözünürlüklü elektro-optik imgelerden yol tespiti yapmak amacıyla yolların hem spektral hem de yapısal özelliklerini kullanarak yeni öznelikler oluşturmaktadır. Oluşturulan bu öznelikler ise yüksek genelleştirme yeteneğine sahip "Adaboost" algoritması ile kuvvetlendirilmiş sınıflandırıcılar eğitmek amacıyla kullanılmaktadır. Algoritma beş ana modülden oluşmaktadır (Şekil 2).

2.2.1 İmge Bölütleme ve Yapısal Puanlama

Uydu fotoğraflarında farklı genişliklerde yolların bulunması ve aynı yol üzerinde bile yolun genişlik değerlerinin değişimler göstermesi yolları yapısal olarak ayırt etmeyi zorlaştıran etmenlerdendir. Buna rağmen, yolların uzun, devamlı ve birbirini takip eden bölütlerden oluşması da yolların en belirgin ortak özelliğidir. Bu gözlemlere dayanılarak geliştirilen yapısal analiz aşaması bölütleri ve bölüt gruplarını sahip oldukları geometrik özellikleri göz önünde bulundurularak incelemektedir.



Şekil 2: Algoritma Akış Şeması


2.2.1.1 İmge Bölütleme

Öncelikle uydu imgesi, ortalama kaydırma [10,11] (mean-shift) tekniği kullanılarak bölütlenmektedir. Bölütleme işlemi iki farklı parametre kümesi kullanılarak yapılmıştır ve sonuçta aynı imge için iki ayrı bölüt maskesi elde edilmiştir. Parametre kümelerinden birincisi, ince yolların çevresindeki büyük bölütler ile karışmasını engelleyecek şekilde detaylı bir

bölütleme işlemi yapmaktadır. İkinci parametre kümesi ise geniş yolların tek bir bölüt haline getirilmesi amacıyla daha az detaylı bir bölütleme işlemi yapmaktadır.

2.2.1.2 Yapısal Puanlama Bağıntısı

Bu çalışmada bölütler için yapılacak analiz için kullanılacak ölçütler Şekil 3'de gösterilmiştir. Şekil 3 örnek bir bölütü, ortadaki kesikli çizgi bölüte ait büyük eksen ve bölütü içine almış kesik çizgilerden oluşmuş dikdörtgen bölütün karakter kutusunu (bounding box) göstermektedir.



Şekil 3: Örnek Bölüt Ölçütleri

Yol bölütlerinin yapısal olarak uzatılmışlık varsayımını doğrulamaları beklenmektedir. Bu çalışmamızda uzatılmışlık özelliği bağıntı (1) ile hesaplanır.

$$\text{İdeal Uzun Eksen} = \text{Uzun Eksen} \times (2 - \text{Doluluk Oranı}) \quad (1)$$

(1) numaralı bağıntıda "doluluk oranı" (extent) değeri, ilgili bölütün karakter kutusunun (bounding box) alanının bölütün alanına oranını göstermektedir. Örneğin, ideal şekildeki (dikdörtgen) bir bölütün "doluluk oranı" değeri 1 olurken, bölüt yapısı ideal durumdan uzaklaştıkça bu değer sıfıra yaklaşmaktadır. Bu bağıntıda, paydaki çarpım ile uzun eksenin ideal durumdaki yaklaşık değeri hesaplanmaktadır. Ayrıca bulunan ideal uzun eksen değerinin bölüt alan değerlerine bölünmesi ile ideal kısa eksen boyunu bulunabilmektedir. Yolların uzatılmışlık özelliği ise bağıntı (2)'de olduğu gibi ideal uzun ve kısa eksenlerin birbirine olan oranı ile ifade edilebilmektedir. Kısaca uzun eksenin değeri arttıkça bölütün yol uzatılmışlık özelliği yükselecektir. Aynı şekilde kısa eksenin değeri arttıkça bölütün uzatılmışlık özelliği düşecektir.

$$\text{Uzatılmışlık Özelliği} = \frac{\text{İdeal Uzun Eksen}}{\text{İdeal Kısa Eksen}} \quad (2)$$

1, 2 ve 3 numaralı bağıntılardan yola çıkılarak, uzatılmışlık puanı, bağıntı (4)'deki gibi hesaplanabilir.

$$\text{Uzatılmışlık Puanı} = \frac{(\text{Uzun Eksen} \times (2 - \text{Doluluk Oranı}))^2}{\text{Alan}} \quad (3)$$

Bağıntı (3), algoritmanın yapısal değerlendirme aşamalarında bölütlere puan vermek amacıyla kullanılacaktır.

2.2.1.3 Yapısal Puanlama Yöntemi

Bu aşamada, daha önceden elde edilen bölütler teker teker incelenerek uzatılmışlık puanı verilir. Ardından, bölütler k-means algoritması ile yönelimlerine (orientation) göre sekiz ayrı sınıfa ayrılır. Her bir sınıfta bulunan birleşik elemanlar da ayrıca puanlanır. Bu sayede tek başına uzatılmışlık özelliği göstermeyen ancak çevresindeki benzer yönelimli bölütler ile birlikte yol özelliği gösteren bölütler belirlenebilmektedir. Bahsedilen bu puanlama aşamalarının ardından toplamda üç farklı puan maskesi elde edilir. Puan maskelerinden iki tanesi bölüm 2.2.1.1'de elde edilen bölütlerin bölüm 2.2.1.2'de anlatılan şekilde puanlanması sonucu ortaya çıkar. Üçüncü

maske ise bölütlerin yönelimlerine göre sınıflandırılmaları ve puanlanmaları ile elde edilen maskedir. Bahsedilen bu üç maske her piksel değeri için uzatılmışlık puanı içermektedir. Sonuç maskesi hesaplanırken puan maskelerinin en büyük değeri alınır. Bu sayede en iyi yapısal puan piksel koordinatına kaydedilmiş olur.

2. 2. 2 Bant Oranlarının Tespiti

Uzaktan algılama çalışmalarında, su, bitki gibi doğal alanların bulunmasında multispektral imgelerin bant oranlarından faydalanılmaktadır. Bu oranlar, ilgili alanın yapısı hakkında bilgi vermektedir. Bu indisler imgelerden yol çıkarımı konusunda direk yardımcı olmasa da, farklı tip uydu imgelerinde benzer değerler vermektedir. Bu çalışmada kullanılan indisler (Çizelge 1) NDVI, NDWI, TVI, SAVI ve ARVI olarak belirlenmiştir.

Çizelge 1: Kullanılan indisler ve bağıntıları

İndis	Bağıntı
NDVI Normalized Difference Vegetation Index	$\frac{(NIR) - Kırmızı(R)}{(NIR) + Kırmızı(R)}$
NDWI Normalized Difference Water Index	$NDWI = \frac{Yeşil(G) - NIR}{Yeşil(G) + NIR}$
TVI Transformed Vegetation Index	$\left(\frac{NIR - R}{NIR + R} + 0.5\right)^{1/2} * 100$
SAVI Soil Adjusted Vegetation Index	$\frac{((NIR - R) / (NIR + R + L)) * (1 + L)}{(1 + L)}$
ARVI The Atmospherically Resistant Vegetation Index	$ARVI = \frac{NIR - (2 * R - B)}{NIR + (2 * R - B)}$

2. 2. 3 Özniteliklerin Oluşturulması

Bu çalışmada gözetimli öğrenme sürecinde kullanılan öznitelikler hem spektral hem de mekansal özellikleri aynı anda içermektedir. Kullanılan öznitelikler, her bant oranı imgesi ile yapısal puan değerlerini içeren imgenin karışımı ile oluşturulmuştur. Bu sayede imgeden imgeye değişiklik gösterebilen spektral özellikler imgeden bağımsız olan yol yapı özellikleri ile harmanlanmıştır. Yapısal puan imgesi ile bant oran imgelerinin harmanlanması için bu çalışmada önerilen bağıntı (4)'de gösterilmiştir.

$$f(x, y) = s(x, y)b(x, y) \quad (4)$$

Bu bağıntıda $f(x, y)$ oluşturulan öznitelik, $s(x, y)$ yapısal puanları içeren imge ve $b(x, y)$ ilgili bant oranı imgesini göstermektedir.

2. 2. 4 Adaboost Kuvvetlendirilmiş Sınıflandırıcısının Eğitilmesi

Makina öğrenmesi alanında kuvvetlendirme teknikleri öğrenme algoritmalarının performansını arttırmak amacıyla kullanılmaktadır. Adaboost (Adaptive Boosting) algoritması

ise zayıf sınıflandırıcıların birleşimi ile oluşturulacak olan kuvvetli bir sınıflandırıcı bulmayı amaçlamaktadır. Bu çalışmada zayıf sınıflayıcı olarak CART (Classification and Regression Trees) kullanılmıştır. Kullanılan karar ağaçlarında yaprak düğümler sınıflandırma sonucunu temsil etmektedirler. Yaprak düğümler dışındaki düğümler ise hangi özneliğin hangi eşik değerlerinden geçirilerek karar verildiği bilgisini içermektedirler.

Karar ağacı oluşturma işlemi için verilen eğitim örneklerini $S = \{(x^1, y^1), \dots, (x^m, y^m)\}$ ile ifade edersek, ikili sınıflandırma problemini çözmemiz gerekmektedir. Burada x^j n boyutlu örnek uzayında bulunan j'inci piksel karşılık gelen öznitelik vektörü ve y^j alınan örneğin sınıfını belirtmektedir: ($y^j \in Y = \{-1, +1\}$ ve $x^j \in R^n$)

Karar ağacının her bir düğümünü oluşturmak için şu yol izlenmektedir;

- Öznitelik vektörünün her boyutu için örnek uzayını en az hata ile ayıran eşik değerleri bulunur.
- Bulunan eşik değerleri arasında en az hata değerine sahip i boyutu için bir düğüm oluşturulur; Oluşturulan düğüm dalları doğru/yanlış olmak üzere uygun sınıflandırma sonucunu içeren yaprak düğümler ile bağlanır.

Karar ağacının bütünü oluşturmak içinde şu yol izlenir;

- Ana (root) düğüm oluşturulur.
- En büyük hataya sahip yaprak düğümü seçilir.
- Eğitim örneklerinden, üzerinde bulunulan yaprak düğümüne atanmış olan örnekler kullanılarak yeni bir düğüm oluşturulur.
- Yaratılan düğüm seçilen yaprak düğümü ile yer değiştirilir.
- Bütün yaprak düğümleri sıfır hataya sahip olana kadar ya da önceden belirlenen bir adım sayısına ulaşıncaya kadar, (ii),(iii) ve (iv) adımları tekrar edilir.

Adaboost algoritması [17] ile yapılan eğitimin amacı zayıf sınıflandırıcıların doğrusal karışımından oluşan kuvvetlendirilmiş bir sınıflandırıcı elde etmektir. Bağıntı (5)'de verilen x örnekler uzayı için T adımda tamamlanan bir kuvvetlendirilmiş sınıflandırıcı gösterilmiştir. Bu bağıntıda $k_1(x)$ i'inci adımda oluşturulan zayıf sınıflandırıcı ve a_1 söz konusu sınıflandırıcının katsayısıdır.

$$C(x) = a_1 k_1(x) + a_2 k_2(x) + \dots + a_T k_T(x) \quad (5)$$

İteratif bir algoritma olan adaboost her adımda yeni bir zayıf sınıflandırıcıyı doğrusal karışıma katsayısı ile birlikte ekler. Her adımda örnek uzayında bulunan elemanların doğru sınıflandırılıp sınıflandırılmadıklarına göre hata hesaplamasında kullanılan ağırlıkları değiştirilir. Doğru sınıflandırılan örneklerin ağırlığı azaltılır, hatalı sınıflandırılan örneklerin ağırlıkları ise artırılır. Bu sayede bir sonraki adımda yaratılacak olan zayıf sınıflandırıcıların yanlış sınıflandırılan örnekleri doğru sınıflandırılmasına odaklanması sağlanır. Adaboost ile eğitilen kuvvetlendirilmiş sınıflandırıcı genelleştirebilme yeteneği sayesinde farklı tipteki yolların (toprak, beton, asfalt) aynı sınıfa yerleştirilmesi mümkündür.

2. 2. 4 Yol Bölgelerinin Sınıflandırılması

Bu aşamada bir önceki aşamada Adaboost öğrenme algoritması ile elde edilen sınıflandırıcı ile test imgelerindeki yol alanları sınıflandırılmaktadır.


3. Deneyle ve Tartışma

Önerilen yöntem, farklı bitki ve arazi örtüsüne sahip 20 farklı IKONOS ve GEOEYE imgelerinde denenmiştir. Görüntülere ait “yer-gerçeklik” (Ground-Truth) bilgisi çıkarılmıştır. Bu yer-gerçeklik bilgisi kullanılarak yol alanlarının öznelikleri belirlenmiş ve Adaboost sınıflandırıcısı eğitilmiştir. Yolların farklı karakteristiklerini en iyi gösteren 5 imge ve yer-gerçeklik bilgisi öğrenme için kullanılmış, geri kalan 15 imge ve yer-gerçeklik bilgileri performans ölçümünde kullanılmıştır. Elde edilen sonuçlar üzerinde piksel bazında kesinlik (precision) ve geri çağırma (recall) başarımları ölçümleri yapılmıştır. Çizelge 2’de elde edilen başarımların sonuçları özetlenmiştir.

Çizelge 2: Başarımların Sonuçları

Kesinlik (Precision)	Geri Çağırma (Recall)	Kesinlik Std Sp.	Geri Çağırma Std Sp.
% 40	% 60	10	8

Şekil 4’de kullanılan imgeler ve algoritma sonucu elde edilen yol maskeleri verilmektedir.



Şekil 4: Örnek imgeler ve algoritma çıktısı

4. Sonuç

Bu çalışmada yüksek çözünürlüklü uydu görüntülerinden otomatik yol çıkarımı hedeflenmektedir. Önerilen yöntem, uydu görüntüsünden bağımsız olarak spektral ve yapısal özellikleri kullanmaktadır. Çalışmada elde edilen veriler arazi sınıflandırmasına ait güncel veri tabanı tutulabilmesi, navigasyon destek sistemleri, acil durum yönetimi ve askeri karar destek sistemleri gibi alanlara katkı sağlayabilir. Alınan ön sonuçlar önerilen yöntemin uydu görüntülerinden yol çıkarımında başarılı olduğunu göstermektedir. Sonuçların iyileştirilmesi için daha fazla görüntü için “yer-gerçeklik” (Ground-Truth) bilgisinin çıkarılması ve algoritmanın daha fazla sayıda ve tipte uydu imgesi üzerinde test edilmesi gerekmektedir. Ayrıca son-işleme modülünün geliştirilmesinin sonuçlardaki gürültüyü azaltması ve kesinlik değerlerini iyileştirmesi beklenmektedir.

5. Teşekkür

Bu çalışmayı destekleyen HAVELSAN A.Ş.’ye teşekkür ederiz.

6. Kaynaklar

- [1] H. Zhao, J. Kumagai, M. Nakagawa, R. Shibasaki, "Semi-automatic Road Extraction from High-resolution Satellite Image," *Proc. Photogrammetric Computer Vision ISPRS Commission III, Symposium*, 406-411, (2002).
- [2] L. Wang, Q. Qin, S. Du, D. Chen, and J. Tao, "Road extraction from remote sensing image based on multi-resolution analysis," *International Symposium on Remote Sensing of Environment*, (2005.)
- [3] V. Shukla, R. Chandrakant, R. Ramachandran, "Semi-Automatic Road Extraction Algorithm For High Resolution Images Using Path Following Approach," *ICVGIP02*, 201-207, (2002)
- [4] C. Zhang, M. Shunji, B. Emmanuel, "Road Network Detection by Mathematical Morphology", *ISPRS Workshop "3D Geospatial Data Production: Meeting Application Requirements"*, 185-200, (1999).
- [5] T. Géraud, J.B. Mouret, "Fast road network extraction in satellite images using mathematical morphology and Markov random fields". *EURASIP Journal of Applied Signal Processing*, 2503-2514, (2004).
- [6] B. Sirmacek, C. Unsalan, "Road Network Extraction Using Edge Detection and Spatial Voting," *ICPR*, 3113-3116, (2010).
- [7] H. Y. Lee, W. Park, H.K. Lee, "Automatic Road Extraction from 1M-Resolution Satellite Images." *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 55, (2000).
- [8] J. Amini, C. Lucas, M.R. Saradjian, A. Azizi, S. Sadeghian, "Fuzzy Logic System For Road Identification Using Ikonos Images", *Photogrammetric Record*, (2002).
- [9] U. Bacher, H. Mayer, "Automatic Road Extraction from Multispectral High Resolution Satellite Images", *ISPRS Object Extraction for 3D City Models, Road Databases and Traffic Monitoring - Concepts, Algorithms and Evaluation*, (2005).

- [10] D. Comanicu, P. Meer: "Mean shift: A robust approach toward feature space analysis." *IEEE Trans. Pattern Anal. Machine Intell.*, 603-619, (2002).
- [11] C.M. Christoudias, B. Georgescu, P. Meer, "Synergism in low level vision," *Proceedings: 16th International Conference on Pattern Recognition*, 150- 155 ,(2002).
- [12] A.R. Huete, "A Soil-Adjusted Vegetation Index (SAVI)". *Remote Sensing of Environment*, vol. 25:295-309, (1988).
- [13] J.Weier, D. Herring. "Measuring Vegetation (NDVI & EVI). *Internet: <http://earthobservatory.nasa.gov/Features/MeasuringVegetation/>*, (2012).
- [14] B. Gao, "NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space", *Remote Sensing of Environment*, vol. 58:257-266,(1996).
- [15] M.D. Nellis, J.M. Briggs, "Transformed Vegetation Index for Measuring Spatial Variation in Drought Impacted Biomass on Konza Prairie, Kansas", *Transactions of the Kansas Academy of Science*, vol. 95: 93-99, (1992).
- [16] Y. J. Kaufman, D. Tanre, "Strategy for Direct and Indirect Methods for Correcting the Aerosol Effect on Remote Sensing: from AVHRR to EOS-MODIS", *Remote Sensing of Environment*, vol 55:65-79, (1996).
- R.E. Schapire , Y. Singer "Improved boosting algorithms using confidence-rated predictions". *Machine Learning*, vol 37:297-336, (1999).