

Arazi Kullanımlarının Sınıflandırılmasında Piksel ve Obje Tabanlı Sınıflandırmanın Karşılaştırılması

DERYA GÜLÇİN¹

¹ Aydın Adnan Menderes Üniversitesi Ziraat Fakültesi Peyzaj Mimarlığı Bölümü, Aydın

Öz: Yüksek çözünürlüklü uydu görüntülerinin sınıflandırılmasıyla oluşturulan arazi örtüsü-arazi kullanımı (AÖ/AK) envanterleri, hem kent ölçeğinde hem de peyzaj ölçeğindeki planlama uygulamalarının yürütülmesi açısından önem taşımaktadır. Avrupa'da alan kullanım planlaması kapsamında hazırlanan kent atlasları, peyzaj ölçeğindeki Natura 2000 ve CORINE veri setlerine dayanan haritalar, uydu görüntülerinin yüksek doğrulukla sınıflandırılması ile oluşturulmaktadır. Sınıflandırma tekniklerinden kontrollü ve kontrolsüz sınıflandırmanın yanı sıra, güncel bir yöntem olan obje tabanlı sınıflama da etkin olarak kullanılmaktadır. Bu çalışmanın materyali olarak, 2013 yılına ait Aydın kentsel yerleşim merkezi sınırındaki 0.5 m yersel çözünürlüğe sahip Worldview Ortoready Pansharpened uydu görüntüsü ve görüntünün yorumlanmasında Google Earth Pro yazılımının geçmiş görüntüleri arasında aynı yılı kapsayan hava fotoğrafları kullanılmıştır. Kentsel alan kullanımlarını örnekleyecek düzeyde seçilen çalışma alanı, kontrollü ve obje tabanlı sınıflandırma tekniği ile sınıflandırılarak, sınıflandırma sonuçları karşılaştırmalı olarak değerlendirilmiştir. Doğruluk analizi sonuçlarına göre, kontrollü sınıflandırma için hesaplanan ortalama doğruluk değeri %82.79, obje tabanlı sınıflandırma için hesaplanan ortalama doğruluk değeri %92.52 olarak elde edilmiştir.

Anahtar Kelimeler: piksel tabanlı sınıflandırma, obje tabanlı sınıflandırma, kentsel alan kullanımları

The Comparison of Pixel and Object-based Classification for Land Use/Land Cover Mapping

Abstract: The classification of high resolution satellite images enable planners and researchers to classify land use/land cover (LULC), which are important in terms of carrying out the planning applications both at city and landscape scale. For conducting different landscape analysis, LULC plays a significant role for numerous applications, such as urban growth analysis, deforestation, etc. Urban atlases provided by European initiatives, Coordination of Information on the Environment (CORINE) and various thematic maps are based on the classification of high resolution satellite images. As a current method, object-based classification is also used effectively in remote sensing researches. The materials of this study are Worldview ortoready pansharpened satellite image with a local resolution of 0.5 m environs the urban settlement of Aydın dated 2013, and the satellite images belong to the same year acquired from Google Earth Pro software. The research area representing urban green space, barren land, road, building, agricultural field, and shadow was chosen to classify urban LULC by supervised classification and object based classification in a comparative way. The results of the accuracy analysis demonstrate that the object-based classifier achieved a high overall accuracy (92.52%), whereas the most commonly used decision rule, namely maximum likelihood classifier, produced a lower overall accuracy (82.79%). This research shows that the object-based classifier is a significantly better approach than the classical pixel classifiers.

Keywords: supervised classification, object based classification, land use/land cover

GİRİŞ

Avrupa Çevre Ajansı (AÇA)'nın belirlediği kriterler ve sınıflandırma sistemi doğrultusunda AÇA'ya üye tüm ülkelerde, arazideki çevresel değişimlerin belirlenmesi, doğal kaynakların rasyonel biçimde yönetilmesi ve çevre ile ilgili politikaların oluşturulması amaçlarına yönelik olarak, aynı temel verilerin toplanması ve standart bir veri tabanının oluşturulmasına yönelik çalışmalar yürütmektedir. CORINE (Coordination of Information on the Environment-Çevresel Bilginin Koordinasyonu) sınıflarına göre alansal değişimin izlenmesinde oluşturulan veri tabanı, üçüncü düzeyde analiz yapmak için yetersizdir. Örnek olarak, 1990 yılına ait veri seti incelenmiş ve “kentsel yeşil alanlar” sınıfının alansal miktarının yer gerçeğine oranla çok sınırlı olduğu gözlemlenmiştir. Sınıflandırma doğruluğu %85'in altında olarak belirtilmiş olmasına rağmen ileri düzeyde bir değişim analizi yapmak mümkün değildir. Bu nedenle kentlere ait kentsel alan kullanım sınıflarının oluşturulmasında güncel görüntü tekniklerinin kullanılması, yapılacak çevresel

analizlerin de doğruluğu açısından önemlidir (Camps-Valls ve ark., 2014; Li ve ark., 2017; Maggiori ve ark., 2017).

Uydu görüntüleri yardımıyla kentsel alan kullanımlarının sınıflandırılmasında farklı algoritmalara (obje tabanlı en yakın komşuluk, destek vektör makineleri, karar ağacı analizleri gibi) dayanan yöntemler kullanılmaktadır (Cristianini ve Shawe-Taylor, 2000; Melgani ve Bruzzone, 2004; Tzotsos ve Argialas, 2008; Ustuner ve ark., 2017). Çözünürlüğü 2.5-4 metre arasındaki Ikonos veya Quickbird gibi yüksek çözünürlüklü görüntüler, bugüne kadar kent paternini tüm detayları ile gösteren haritaların üretilmesini sağlamıştır. Geleneksel sınıflandırma yöntemleri, görüntüdeki spektral bilgi veya renklere dayanan piksel yaklaşımlarını (Bayes teoremi veya yapay sinir ağları) benimsemektedir (Schowengerdt, 2012). Ancak bu sınıflandırmada, üretilen haritalardaki sınıfların doğruluğu sınırlıdır. Bir diğer ifadeyle,

Sorumlu Yazar: derya.yazgi@adu.edu.tr

Geliş Tarihi: 15 Mayıs 2018

Kabul Tarihi: 7 Aralık 2018


uydu görüntülerinin mekânsal çözünürlüğünün artması ile içerdikleri zengin bilgi içerikleri, piksel tabanlı sınıflandırmada tutarsız sonuçlar gösterebilmektedir. Bu nedenle günümüzde, piksellerin yanında anlamlı nesnelere ve karşılıklı ilişkilerle görüntünün sınıflandırılmasını sağlayan obje tabanlı sınıflandırma tekniği kullanılmaktadır (Blaschke ve ark., 2004; Blaschke, 2010; Dingle Robertson ve King, 2011; Whiteside ve ark., 2011; Duro ve ark., 2012). Renk, doku, sıklık ve komşuluk gibi belirli özellikleri referans alan obje tabanlı sınıflandırma, benzer spektral özelliklere sahip piksellerin gruplandırılarak görüntüde anlamlı nesnelere oluşturulması temeline dayanmaktadır.

Bu çalışmanın amacı, Aydın kent merkezinde, kentsel alan kullanımlarını örnekleyecek düzeyde seçilen test alanını, kontrollü ve obje tabanlı sınıflandırma tekniği ile sınıflandırılarak, sınıflandırma sonuçları karşılaştırmalı olarak değerlendirmektir. Obje tabanlı sınıflandırmada, eCognition

Developer 9.0 yazılımı kullanılarak segmentasyon aşamasında çoklu çözünürlük algoritmasından (*Multiresolution Segmentation*) faydalanılmıştır. Segmentasyon aşamasında, ölçek değerinin doğru belirlenebilmesi için çok sayıda deneme yapılmış ve sınıflandırmanın başarısı kontrol edilmiştir.

MATERYAL ve YÖNTEM

Bu çalışmanın materyalini, 2013 yılına ait Aydın kentsel yerleşim merkezi sınırındaki 0.5 m yersel çözünürlüğe sahip *Worldview Ortoready pansharpened* uydu görüntüsü ve görüntünün yorumlanmasında Google Earth Pro yazılımının geçmiş görüntüleri arasında aynı yılı kapsayan hava fotoğrafları oluşturmaktadır. Çalışma alanı, UTM koordinat sistemine göre 37°49'-37°51'K ve 27°48'-27°50'D arasında yer almaktadır ve yaklaşık 1.500 hektar alan kaplamaktadır (Şekil 1).



Şekil 1. Çalışma alanı

Kentsel alan kullanımlarını örnekleyecek düzeyde seçilen test alanında; konut, yol, tarım alanı, kentsel yeşil alanlar ve diğer açık alanlar olmak üzere toplam 5 sınıf bulunmaktadır. Piksel tabanlı sınıflandırma için ArcMap 10.5 yazılımı, obje tabanlı sınıflandırma için ise eCognition Developer 9.0 yazılımı kullanılmıştır. Segmentasyon aşamasında çoklu çözünürlük algoritmasından (*Multiresolution Segmentation*) faydalanılmıştır. Çalışmanın yöntem akış şeması Şekil 2'de sunulmuştur.

Yapılan işlemlerin doğruluğunu test etmek amacıyla, piksel değerlerinin referans olarak kabul edilen haritalar veya araziye ait yer gerçekleri ile istatistiksel olarak karşılaştırılması yapılmaktadır. Hata ölçüsünü belirlemek için hata matrisi kullanılmaktadır. Hata matrislerinden elde

edilen sınıflar arası doğrulukların belirlenmesinde, Kappa (K) katsayısı kullanılmaktadır (Cohen, 1960; Campbell, 1996).

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

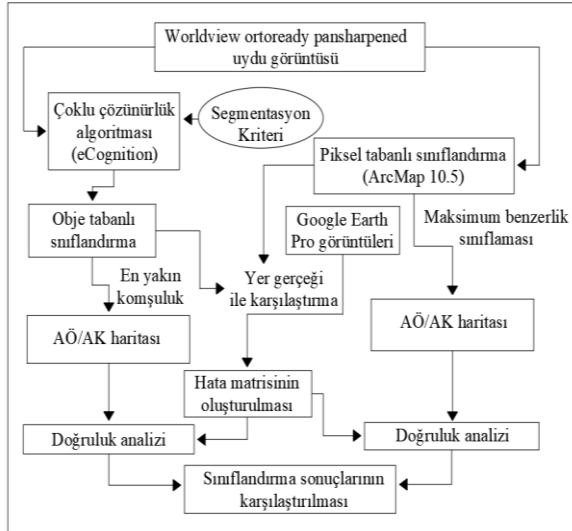
r : Hata matrisindeki satırların sayısı

x_{ii} : Satır i ve sütün i'deki gözlemlerin sayısı

x_{i+} : Satır i'deki toplam gözlem

x_{+i} : Sütün i'deki toplam gözlem

N : Matriste içerilen toplam gözlem sayısı




Şekil 2. Yöntem akış şeması (Rahman ve Saha, 2008'den değiştirilerek)

Doğruluk analizinde genel doğruluk, tüm doğru atanmış piksel sayısı/tüm pikseller sayısını; kullanıcı doğruluğu, bir sınıfa ait doğru sınıflandırılan piksel sayısı/o sınıftaki toplam piksel sayısını; üretici doğruluğu ise bir sınıfa ait doğru sınıflandırılan piksel sayısı/bir sınıftaki olması gereken gerçek piksel sayısını ifade etmektedir (Congalton, 1991; Jensen, 2005).

BULGULAR ve TARTIŞMA


Kontrollü sınıflandırma yöntemine göre, sınıflandırmanın kullanıcı tarafından belirlenmesinde referans alınabilecek hava fotoğrafları, çeşitli haritalar ya da arazi sürveyleri kullanılabilir (Mather, 1987). Bu yöntemin uygulanmasında, 2013 yılına ait hava fotoğraflarından yararlanılarak her bir sınıflandırma alanı için 100 adet test alanı seçilmiştir. Maksimum benzerlik algoritması ile kullanılarak oluşturulan kontrollü sınıflandırılmış görüntü Şekil 3'de sunulmuştur. Sınıflandırma sonucunda tarım alanları ile kentsel yeşil alanların benzer spektral özelliklere sahip olması nedeniyle karışmış olduğu görülmektedir. Aynı durum, yol ile açık alanlar sınıfı için de geçerlidir.




Şekil 3. Kontrollü sınıflandırma sonucu

Objeye tabanlı sınıflandırmanın ilk aşaması segmentasyondur. Segmentasyon, benzer spektral özelliklere sahip piksellerin gruplandırılarak, mekânsal karakteri farklı objelere bölünmesi işlemidir (Ryherd ve Woodcock, 1996; Baatz ve ark., 2004; Kalkan, 2011). Komşu piksellerin bir araya getirilmesi ile belirli poligonların veya görüntü nesnelere oluşturulması için bu aşamada çok sayıda test yapılmıştır (Şekil 4).

Çoklu çözünürlük algoritmasının (*Multiresolution Segmentation*) uygulanmasında, şekil, yoğunluk ve ölçek parametrelerinin doğru belirlenmesi önemlidir (Benz ve ark., 2004). Yapılan testler sonucunda, sınıflandırma ölçeği olarak 50, şekil ve yoğunluk parametreleri için sırasıyla 0.1 ve 0.5 değerleri kullanılmıştır. Sınıflandırma sonucu Şekil 5'de sunulmuştur.



Şekil 4. Örnek bir test alanına ait segmentasyon ölçek değerleri: 20 (sol üst), 50 (sağ üst), 70 (sol alt), 100 (sağ alt). (Mavi renkteki çizgiler objelerin ayrılma sınırlarını göstermektedir)



Şekil 5. Objeye tabanlı sınıflandırma yöntemi ile sınıflandırılmış görüntü

Doğruluk analizinin yapılması amacıyla sınıflanmış görüntü üzerinden toplam 198 kontrol noktası belirlenmiştir. Bu çalışma kapsamında, kontrollü sınıflandırma ve obje tabanlı


sınıflandırma sonucu oluşturulan görüntüleri ait doğruluk analizi sonuçları Çizelge 1'de sunulmuştur.

Çizelge 1. Doğruluk analizi sonuçları

Sınıf Adı	Kontrollü Sınıflandırma (KS)		Obje Tabanlı Sınıflandırma (OTS)	
	(KS) Üretici Doğruluğu (%)	(KS) Kullanıcı Doğruluğu (%)	(OTS) Üretici Doğruluğu (%)	(OTS) Kullanıcı Doğruluğu (%)
Tarım alanı	70.32	85.33	89.01	92.05
Açık alan	70.27	78.79	91.89	77.27
Konut	65.85	84.38	92.68	95.00
Yol	87.87	87.88	93.93	91.18
Gölge	91.76	96.30	96.47	97.62
Kentsel yeşil alan	94.73	73.47	92.10	94.59
Toplam doğruluk (%)	82.79		92.52	
Kappa (K)	0.82		0.92	

Doğruluk analizi sonuçları incelendiğinde, kontrollü sınıflandırma için hesaplanan ortalama doğruluk değeri %82.79 iken, obje tabanlı sınıflandırma için hesaplanan ortalama doğruluk değeri %92.52'dir. Kontrollü sınıflandırmada, gölge alanlar hem üretici hem de kullanıcı doğruluğunun en yüksek olduğu sınıfa karşılık gelmektedir. Tarım alanı ve açık alanların üretici doğruluğu yaklaşık %70

iken, kentsel yeşil alanların doğruluk değeri %94.73'tür. Objeye tabanlı sınıflandırma için elde edilen doğruluk değerleri genel olarak %90'ın üzerindedir. Gölge alanların doğruluk değerleri kontrollü sınıflandırmada olduğu gibi en yüksek olmakla birlikte, üretici doğruluğu en yüksek ikinci sınıftadır (Şekil 6).



Şekil 6. Her iki sınıflandırmaya ait üretici ve kullanıcı doğruluğu değerleri (%)

SONUÇ

Yüksek çözünürlüklü uydu görüntülerinin sınıflandırılmasıyla oluşturulan arazi örtüsü-arazi kullanımı (AÖ/AK) envanterleri, hem kent ölçeğinde hem de peyzaj ölçeğindeki planlama uygulamalarının yürütülmesi açısından önemlidir. Doğru sınıflandırma tekniklerinin kullanılması, özellikle çevresel izleme ve değişim çalışmalarının yürütülmesinde

etkilidir (Chen ve ark., 2012; Hussain ve ark. 2013; Yu ve ark., 2016). Avrupa'da alan kullanım planlaması kapsamında hazırlanan kent atlasları, peyzaj ölçeğindeki Natura 2000 ve CORINE AÖ veri setlerinin kombinasyonuna dayanan haritalar, uydu görüntülerinin yüksek doğrulukla sınıflandırılması ile oluşturulmaktadır.

Avrupa Çevre Ajansı'na üye tüm ülkelerde, erişilebilir bir CORINE veri tabanı oluşturulmuştur. Türkiye'de kentlere ait arazi kullanımı sınıflarını CORINE'in tüm düzeylerinde mevcut gösteren veri tabanında özellikle ikinci ve üçüncü düzey sınıflarda hatalar olduğu tespit edilmiştir. Kentlere ait arazi kullanımı sınıflarının belirlenmesinde, yüksek doğrulukla sınıflandırılmış verinin kullanılması, yapılacak peyzaj analizi çalışmalarının doğruluğu açısından da büyük önem taşımaktadır.

Bu çalışma kapsamında yapılan doğruluk analizi sonuçları incelendiğinde, kontrollü sınıflandırma için K değeri 0.82 iken, obje tabanlı sınıflandırma için hesaplanan K değeri 0.92'dir. Kontrollü sınıflandırma ve obje tabanlı sınıflandırma sonucunda, obje tabanlı sınıflandırmanın doğruluğunun daha yüksek seviyede olduğu görülmüştür. Gölge alanların sınıflandırma doğruluğu her iki sınıflandırmada da çok yüksek çıksa da, bu alanlar sınıflandırma açısından sorun yaratmaktadır (Zhou ve ark., 2009; Zhu ve Woodcock, 2012). Farklı algoritmalar geliştirilerek, bu alanların sınıflandırmadan otomatik olarak çıkarılmasına yönelik çalışmaların yapılması ileride yapılacak diğer çalışmalar için de katkı sağlayacaktır.

Güncel olarak yapılan çalışmaların çoğunda, yüksek mekânsal çözünürlük ve yüksek spektral çözünürlüğe sahip görüntüler için arazi kullanımının belirlenmesinde obje tabanlı yaklaşımın yüksek doğrulukta sonuçlar verdiği gözlemlenmiştir (Plat ve Rapoza, 2008; Kalkan ve Maktav, 2010; Tehrany ve ark., 2013; Yu ve ark., 2016). Ayrıca, bu sınıflandırma ile yapılan hatalar ya da hatalı sınıf atamaların hızlı bir şekilde düzeltilebileceği belirtilmiştir.

Yüksek doğruluk gösteren AÖ/AK'nın sınıflandırılması; kentsel planlama çalışmalarında, peyzaj analizlerinde, çevresel değişim ve izleme çalışmalarında altlık veri olarak kullanılmaktadır. Bu nedenle, uzaktan algılama çalışmalarında tercih edilen sınıflandırma yöntemleri arasında obje tabanlı sınıflandırma genellikle yüksek doğrulukta sonuçlar ürettiği için tercih edilebilir.

KAYNAKLAR

Baatz M, Benz U, Dehghani S, Heynen M, Höltje A, Hofmann P, Lingenfelder I, Mimler M, Sohlbach, M, Weber M, Willhauck G (2004) eCognition Professional User Guide, Version 4.0. Definiens Imaging GmbH. München, Germany: Definiens.

Benz UC, Hofmann P, Willhauck G, Lingenfelder I, Heyen M (2004) Multi-resolution, Object-oriented Fuzzy Analysis of Remote Sensing Data for GIS-ready Information. ISPRS Journal of Photogrammetry & Remote Sensing 58: 239–58.

Blaschke T (2010) Object based image analysis for remote sensing. ISPRS Journal of Photogrammetry and Remote Sensing, 65(1): 2-16.

Blaschke T, Burnett C, Pekkarinen A (2004) Image segmentation methods for object-based analysis and classification. In Remote sensing image analysis: Including the spatial domain (pp. 211-236). Springer, Dordrecht.

Campbell JB (1996) Introduction to Remote Sensing. Guilford Press, New York.

Camps-Valls G, Tuia D, Bruzzone L, Benediktsson JA (2014) Advances in hyperspectral image classification: Earth monitoring with statistical learning methods. IEEE Signal Processing Magazine, 31(1): 45-54.

Chen G, Hay GJ, Carvalho LM, Wulder MA (2012) Object-based change detection. International Journal of Remote Sensing, 33(14): 4434-4457.

Cohen J (1960) A Coefficient of Agreement for Nominal Scales. Educational and Psychological Measurement, 20 (1): 37-46.

Congalton RG (1991) A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment, 37(1): 35-46.

Cristianini N, Shawe-Taylor J (2000) An introduction to support vector machines and other kernel-based learning methods. Cambridge University Press, 187s.

Dingle Robertson L, King DJ (2011) Comparison of pixel- and object-based classification in land cover change mapping. International Journal of Remote Sensing, 32(6):1505-1529.

Duro DC, Franklin SE, Dubé MG (2012) A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. Remote Sensing of Environment, 118: 259-272.

Hussain M, Chen D, Cheng A, Wei H, Stanley D (2013) Change detection from remotely sensed images: From pixel-based to object-based approaches. ISPRS Journal of Photogrammetry and Remote Sensing, 80: 91-106.

Jensen JR (2005) Introductory Digital Image Processing: A Remote Sensing Perspective. Pearson Prentice Hall, Upper Saddle River, NJ.

Kalkan K (2011) Kentsel Gelişim için Potansiyel Açık Alanların Belirlenmesinde Nesne Tabanlı Sınıflandırma Yöntemi ile Transfer Edilebilir Kural Dizisi Oluşturulması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Kalkan K, Maktav D (2010) Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği). III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 – 13 Ekim 2010, Gebze – Kocaeli.

Li W, Wu G, Zhang F, Du Q (2017) Hyperspectral image classification using deep pixel-pair features. IEEE Transactions on Geoscience and Remote Sensing, 55(2): 844-853.

- Maggiore E, Tarabalka Y, Charpiat G, Alliez P (2017) Convolutional neural networks for large-scale remote-sensing image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2): 645-657.
- Mather P M (1987) *Computer Processing of Remotely Sensed Images: An Introduction*, John Wiley & Sons Ltd., 360s.
- Melgani F, Bruzzone L (2004) Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8): 1778-1790.
- Platt R V, Rapoza L (2008) An Evaluation of an Object-Oriented Paradigm for Land Use/Land Cover Classification. *The Professional Geographer*, 60 (1): 87-100.
- Rahman MR, Saha SK (2008) Multi-Resolution Segmentation for Object-based Classification and Accuracy Assessment of Land Use/Land Cover Classification Using Remotely Sensed Data. *Journal of the Indian Society of Remote Sensing*, 36(2): 189-201.
- Ryherd S, Woodcock C (1996) Combining Spectral and Texture Data in the Segmentation of Remotely Sensed Images. *Photogrammetric Engineering and Remote Sensing*, 62: 181-194.
- Schowengerdt, RA (2012) *Techniques for image processing and classifications in remote sensing*. Academic Press, 249s.
- Tehrany MS, Pradhan B, Jebuv MN (2014) A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using SPOT 5 imagery. *Geocarto International*, 29(4): 351-369.
- Tzotsos A, Argialas D (2008) Support vector machine classification for object-based image analysis. In *Object-Based Image Analysis* (pp. 663-677). Springer, Berlin, Heidelberg.
- Ustuner M, Sanli FB, Dixon B (2015) Application of support vector machines for landuse classification using high-resolution RapidEye images: a sensitivity analysis. *European Journal of Remote Sensing*, 48(1): 403-422.
- Whiteside TG, Boggs GS, Maier SW (2011) Comparing object-based and pixel-based classifications for mapping savannas. *International Journal of Applied Earth Observation and Geoinformation*, 13(6): 884-893.
- Yu W, Zhou W, Qian Y, Yan J (2016) A new approach for land cover classification and change analysis: Integrating backdating and an object-based method. *Remote Sensing of Environment*, 177: 37-47.
- Zhou W, Huang, G, Troy A, Cadenasso ML (2009) Object-based land cover classification of shaded areas in high spatial resolution imagery of urban areas: A comparison study. *Remote Sensing of Environment*, 113(8): 1769-1777.
- Zhu Z, Woodcock CE (2012) Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118: 83-94.

