

Ormanlık alanlar için nesne tabanlı sınıflandırma sonuçları ile arazi verisinin karşılaştırılması

Comparison of object-based classification results and field data for forested areas

Duygu BIYIKLI^{1*}, Aycan Murat MARANGOZ²

¹Kastamonu Üniversitesi, İhsangazi Meslek Yüksek Okulu, Harita ve Kadastro Programı, Kastamonu, Türkiye

²Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, Zonguldak, Türkiye

Eser Bilgisi / Article Info

Araştırma makalesi / Research article

DOI: 10.17474/artvinofd.1322949

Sorumlu yazar / Corresponding author

Duygu BIYIKLI

e-mail: dbiyikli@gmail.com

Geliş tarihi / Received

05.07.2023

Düzeltilme tarihi / Received in revised form

11.12.2023

Kabul Tarihi / Accepted

28.12.2023

Elektronik erişim / Online available

15.05.2024

Anahtar kelimeler:

Nesne tabanlı sınıflandırma

eCognition yazılımı

GeoEye-1

Arazi verisi

Keywords:

Object-based classification

eCognition software

GeoEye-1

Land data

Özet

Ormanlık alanda gerçekleştirilen bu çalışmanın amacı, hem nesne tabanlı sınıflandırma yönteminin başarısını hem de sınıflandırma öncesi ihtiyaç duyulan referans veri ihtiyacı için arazi çalışmasının yeterli olup olmayacağını araştırmaktır. Nesne tabanlı sınıflandırma yönteminde sınıflandırma öncesi hem segmentasyon parametrelerinin hem de doğruluk analizi için seçilecek eğitim alanlarının seçiminde çoğu zaman hava fotoğrafları, paftalar, meşcere haritaları, arazi verisi gibi referans veriye ihtiyaç duyulmaktadır. Bu çalışma da ilk olarak Kastamonu İli Merkez Orman Şefliğine ait 12x12 km'lik çalışma alanı içerisinde belirlenen "İbrelî, Yapraklı, Tarım alanı, Açık alan ve Bina" sınıf türlerine ait detay çıkarımı için yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden eCognition Developer 9.1 yazılımı kullanılarak, nesne tabanlı sınıflandırma yöntemi ile değerlendirme yapılmıştır. Değerlendirme sonrası Diferansiyel Küresel Navigasyon Sistemi yöntemi ile her sınıftan 30 adet olmak üzere toplamda 150 adet nokta ile arazi çalışması yürütülmüş ve sonuçlar nesne tabanlı sınıflandırma sonuçları ile nokta bazında analiz edilmiştir. Araştırma bulgularına göre, arazi verisinin sınıflandırılmış uydu görüntüsü ile yeterli miktarda uyumlu ve referans veri olarak kullanılabilir olduğu sonucu elde edilmiştir.

Abstract

The aim of this study, which was carried out in the forest area, was to investigate both the success of the object-based classification method and whether the field study would be sufficient for the reference data needed before classification. In the object-based classification method, before classification, reference data such as aerial photographs, layouts, stand maps, field data are often needed in the selection of both segmentation parameters and training areas for the accuracy analysis. In this study, firstly, eCognition Developer 9.1 software was used on high resolution GeoEye-1 satellite image for a detailed extraction of "Coniferous, Broad-leaved, Agricultural field, Open field and Building" class types determined within the 12x12 km study area of Kastamonu Central Forest Department. Evaluation was made by using object-based classification method. After the evaluation, field studies were conducted with the Differential Global Navigation System method using a total of 150 points, 30 from each class, and the results were analyzed on a point basis with object-based classification results. According to the findings, it was concluded that the field data was sufficiently compatible with the classified satellite image and could be used as reference data.

GİRİŞ

Son yıllarda algılayıcı teknolojilerindeki gelişmeler ile birlikte ormanlık, kentsel ve kırsal alanlarda nesnelere ait detay çıkarımı, yüksek çözünürlüklü uydu görüntüleri ve çeşitli yazılımlar kullanılarak yüksek hassasiyetle yapılabilmektedir (Xu ve Shi 2017). GeoEye, Worldview gibi uydu görüntülerinin sağladığı yüksek konumsal, spektral ve radyometrik çözünürlüğe bağlı olarak istenilen doğrulukla veri üretmek de mümkündür (Köhl ve ark. 2006, Heintz ve ark. 2009).

Uydu görüntüleri üzerinden, herhangi boyuttaki nesnelerin belirlenebilmesi için en yaygın kullanılan yöntem görüntülerin sınıflandırılmasıdır. Sınıflandırma piksel ve nesne tabanlı olarak yapılabilmektedir. Her ikisi için de ortak olan, spektral özelliğın kullanılarak yapılıyor olmasıdır. En basit hâliyle sınıflandırma yeryüzü nesnelerinin, benzer spektral özelliğe sahip sınıflara atanması işlemidir (Kesikoğlu ve ark. 2020). Uydu görüntüleri üzerinden sınıflandırma yapılabilmesi için birçok algoritma ve ticari yazılım geliştirilmiştir (Lu ve Weng 2007, Tso ve Mather 2009, Li ve ark. 2014). Literatürde yapılan çalışmalar incelendiğinde ilk olarak piksel tabanlı sınıflandırma yönteminin geliştiği;

sonrasında ise nesne tabanlı sınıflandırmaya geçişin olduğu görülmektedir. Görüntü üzerinde nesneler genellikle farklı spektral özelliklere sahip heterojen piksellerden oluşmaktadır. Bu durum benzer spektral özelliğe sahip farklı nesnelerin sınıflandırılmasında, sınıflandırma doğruluğunu olumsuz yönde etkilemektedir. Bu nedenle de piksel tabanlı sınıflandırma yöntemi, sadece spektral özelliği kullanarak yetersiz kaldığı ve özellikle yüksek çözünürlüklü uydu görüntüleri için çok daha fazla tuz-biber etkisi adı verilen görüntü sorununa neden olduğu için, nesne tabanlı sınıflandırmaya göre daha az tercih edilmektedir (Myint ve ark. 2011, Kavzoglu ve Tonbul 2018). Son yıllarda Yılmaz ve ark. (2018), Sevgen (2019), Ahadi ve Kaplan (2022), Sefercik ve ark. (2023) ve Tırmanoğlu ve ark. (2023) arazi örtüsü ve kullanımı; Apaydın ve Abdikan (2021) tarım arazileri; Saraloğlu (2021) ve Avcı ve ark. (2023)'da ormanlık alanlar için yaptıkları çalışmalarında, piksel tabanlı sınıflandırma yöntemini kullanmayı tercih etmişlerdir. Nesne tabanlı sınıflandırma yöntemi ise piksel tabanlı sınıflandırmadan farklı olarak sadece spektral bilgiye göre değil; şekil, boyut ve komşuluk ilişkileri gibi parametreleri de dâhil ederek, nesnenin daha gerçeğe yakın elde edilebilmesini sağlamaktadır. Bu şekilde çalışmadan istenilen homojenlik kriteri de kullanıcıya sunabilmektedir (Ma ve ark. 2017).

Nesne tabanlı sınıflandırma yönteminin ilk ve en önemli işlem adımı segmentasyondur. Segmentasyon görüntü üzerindeki nesneleri anlamlı gruplara ayırarak, doğru sınıflandırma yapılmasını sağlamaktadır. Ölçek, şekil ve bütünlük parametrelerinin kullanıldığı çoklu çözünürlük segmentasyon algoritması uygulamalarda sıklıkla tercih edilmektedir (Blaschke ve ark. 2008). Çalışmadan istenilen hassasiyet ve görüntü üzerinden sınıflandırılacak nesnelerin homojen sınıflandırılması için segmentasyon parametrelerini deneme-yanılma yaklaşımı ile belirlemek mümkündür. Çalışma alanları özelinde kullanılacak segmentasyon parametrelerinin değer seçimleri için kesin yargılar bulunmamaktadır. Farklı segmentasyon parametreleri deneyerek, yüksek doğruluklu sınıflandırma başarısı elde etmek için yapılan çalışmalar arasında Haralick ve Shapiro (1985), Pal ve Pal (1993), Blaschke (2010), Chen ve ark. (2018) ve Kavzaoğlu ve ark. (2021) yer almaktadır. Blaschke (2010) nesne tabanlı

sınıflandırma yöntemi ve segmentasyon için geliştirilen algoritmaları incelemek adına 800'den fazla çalışma incelemiş ve bir derleme makale yayınlamıştır. Bu bağlamda nesne tabanlı sınıflandırmanın özellikle piksel tabanlı sınıflandırmaya göre üstünlüğünü genel olarak çalışma sonuçlarında gözlemlemiş ve Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) alanlarında oldukça önemli bir yer edindiğini de analiz etmiştir.

Literatürde birçok farklı çalışma alanı için özellikle nesne tabanlı sınıflandırma yöntemi ile uygulamalar yapıldığı görülmektedir. Arazi örtüsü/kullanımı için Zhang ve ark. (2014), Doxani ve ark. (2015) ile Yiğit ve Uysal (2019); binaların çıkarımı için Belgiu ve Drăgut (2016), Kabadayı ve Uysal (2020); kıyı alanları için Ersoy ve ark. (2019); orman örtü tipleri için Wells (2010) ve Machala ve Zejdová (2014); orman yangını öncesi ve sonrasının analizi için Mitri ve Gitas (2004), Dragozi ve ark. (2014); yolların çıkarımı için Bayramoglu ve Uzar (2023) ve heyelan alanlarındaki değişimlerin gözlemlenmesi için de Aksoy ve Ercanoglu (2012), Dou ve ark. (2015) ve Çömert (2020)'in yaptıkları bu çalışmalardan bazılarıdır.

Sınıflandırma işleminin yüksek doğrulukla yapılabilmesi için segmentasyon aşaması kadar, sınıflara ait seçilecek eğitim alanlarının doğrulukla seçilmesi de oldukça önemlidir. Bölgeye ait uydu görüntüsünün konumsal, spektral ve radyometrik çözünürlüğünün çalışmanın hassasiyeti için yeterli olmadığı durumlarda, eğitim alanlarının seçiminde kullanıcı yanılgıya düşebilmekte ve bu gibi durumlarda da ek verilere ihtiyaç duyulmaktadır. Uydu görüntüsü üzerinden nesneler sınıflara atanırken, o bölgeye ait hava fotoğrafları, meşcere haritaları, ormanlık alanlara ait ya da kadastral paftalar ve özellikle arazi verisi, referans veri olarak tercih edilmektedir.

Bu çalışmada yüksek çözünürlüklü GeoEye-1 uydu görüntüsü kullanılarak, Kastamonu ili Merkez Orman İşletme Şefliğine ait sınırlar içerisinde "İbrelî, Yapraklı, Açık alan, Tarım alanı ve Bina" olmak üzere beş farklı sınıf tipi belirlenerek nesne tabanlı sınıflandırma yapılmış olup sonuçlar yersel ölçümle yapılan arazi çalışması ile karşılaştırılmıştır. Arazi çalışması için her sınıftan 30 adet nokta alımı yapılmıştır. Nesne tabanlı sınıflandırma uygulaması için eCognition Developer 9.1 yazılımı; arazi

çalışması için de yüksek doğruluklu konum bilgisi verdiği için Global Navigation Satellite System (GNSS) tercih edilmiştir. Arazi verisi yapıldığı tarih itibarıyla diğer referans verilere oranla en güncel veridir. Bu nedenle sınıflandırma analizlerinde özellikle sınıf çıkarımlarının görüntü üzerinden yapılması aşamasında, geçmiş tarihli verilerin kullanılması yerine güncel veriyi kullanmak daha doğru sonuçların elde edilmesini sağlamaktadır. Çalışmada sınıflandırılmış görüntü ile arazi verisinin karşılaştırılması için öncelikle, yüksek doğruluklu sınıflandırma başarısı elde edilmelidir. Çalışmanın amacı da ilk olarak yüksek doğruluklu sınıflandırma sonucu elde edebilmek ve bu sonuçları arazi verisi ile karşılaştırarak, referans veri olarak kullanılıp kullanılamayacağını araştırılmasıdır.

MATERYAL ve YÖNTEM

Materyal

Kastamonu İli, Merkez Orman İşletme Şefliği sınırları içerisinde 12x12 km'lik bir bölüm çalışma alanı olarak belirlenmiştir. Yoğun ormanlık alanların bulunduğu bu bölümün seçilmesinin nedeni, yapraklı ve ibrelili ağaç türlerinin haricinde tarım alanı, orman içi boşluklar ve yolları kapsayan açık alan ve yerleşim alanına ait bina sınıf türlerinin mevcut olmasından kaynaklanmıştır. Çalışmada hem yüksek çözünürlüklü GeoEye-1 uydu görüntüsü hem de arazi verisi ile analizler gerçekleştirilmiştir. GeoEye-1 uydu görüntüsü, ticari gözlem uyduları içerisinde en yüksek çözünürlüğe sahip uydular arasında yer almaktadır. GeoEye-1 uydu görüntüsünün yüksek konumsal çözünürlüğe sahip olmasının yanı sıra özellikle ormanlık alanların belirlenmesinde kullanılan yakın kızılötesi banta sahip olması nedeniyle de bu çalışmada kullanılmasına karar verilmiştir. Çizelge 1'de GeoEye-1 uydusunun teknik özellikleri gösterilmektedir.


Çizelge 1. GeoEye-1 uydu görüntüsünün teknik özellikleri (URL-1)

Yerel çözünürlük (Pan / MS)	0,41 m / 1,65 m
Spektral çözünürlük (Pan / MS)	450-800 nm (pankroatik) 450-510 nm (mavi) 510-580 nm (yeşil) 655-690 nm (kırmızı) 780-920 nm (yakın IR)
Çerçeve genişliği	15,2 km
Off-nadir görüntüleme	60 dereceye kadar
Dinamik aralığı	11 bit
Uydu ömrü- tahmini	10 yıldan fazla
Yeniden geçiş aralığı	3 günden az
Yörüngesel yüksekliği	681 km

Çalışmada kullanılan GeoEye-1 uydu görüntüsünün başka bir projede kullanılmak üzere Kastamonu Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü hocaları tarafından radyometrik ve geometrik düzeltmeleri yapılmıştır. Görüntü, 32 Yer Kontrol Noktası (YKN) kullanılarak 8 cm konumsal doğrulukla ortorektifiye edilmiştir. Ormancılık çalışmalarında ağaç türlerinin birbirleri içinde ve diğer arazi örtüsü sınıflarından ayırmalarının rahatlıkla yapılabilmesi için genellikle yakın kızılötesi banta sahip uydu görüntüleri ile çalışılmaktadır (Kavzaoglu ve ark. 2021). Bunun nedeni bitkilerin sahip olduğu ve kendilerine yeşil rengi veren klorofilin bu bantta çok az soğurulması ve orman örtü tiplerindeki spektral farklılığın bu şekilde yüksek çözünürlüklü görüntüye yansiyabilmesinden kaynaklanmaktadır (Lillesand ve ark. 2015). Uydu görüntüsünün alım zamanı da oldukça önemlidir. Özellikle mevsimlere dikkat edilmeli ve klorofil seviyesinin yüksek olduğu aylar tercih edilmelidir. Bu çalışmada kullanılan GeoEye-1 uydu görüntüsü Eylül ayında alınmış olmasına rağmen özellikle yapay renkli uydu görüntüsünde, ağaç türlerinin ayırt edilebilirliklerinin yüksek olduğu görülmektedir. Şekil 1'de doğal renkli, Şekil 2'de de bant sıralaması değiştirilerek, yakın kızılötesi bandın öne çıkarıldığı yapay renkli GeoEye-1 uydu görüntüsü gösterilmektedir. Sınıflandırma işlemi Yakın Kızılötesi/Yeşil/Kırmızı renk kompoziti kullanılarak elde edilen yapay renkli uydu görüntüsü ile yapılmıştır.



Şekil 1. Çalışma alanının ait Geoeye-1 uydu görüntüsü



Şekil 2. Çalışma alanına ait yapay renkli GeoEye-1 uydu görüntüsü

Nesne tabanlı sınıflandırma için Definiens firması tarafından geliştirilen ve günümüzde Trimble firmasına ait olan eCognition yazılımı kullanılmıştır. Bu yazılımın tercih edilmesinin nedeni sınıflandırmada meydana gelebilecek eksiklik ve sınırlamaları minimuma indirmek amacı ile üretilmiş olmasıdır. Ayrıca nesne tabanlı sınıflandırma yapan diğer yazılımlara göre de daha kapsamlı ve olumlu sonuçlar vermektedir. Arazi verisi ve sınıflandırılmış raster görüntünün görsel ve sayısal olarak karşılaştırılması için de NetCAD v5.2 yazılımının kullanılması tercih edilmiştir. Hassas koordinatlı veri ile çalışan NetCAD yazılımının bu çalışmada tercih edilmesinin en önemli nedeni, kendi bünyesinde bulundurduğu, farklı koordinat sistemleri için dönüşüm parametrelerinin olmasıdır. Arazi verisi ve uydu görüntüsünün koordinat sistemleri arasında fark bulunmasından kaynaklı; ekstra bir dönüşüm parametresi

hazırlama aşamasına bu sayede gerek duyulmamıştır. Ayrıca yazılımın raster veri üzerinde işlem yapabilme kolaylığı sunması da tercih edilme sebepleri arasındadır. Arazi çalışması kapsamında, çalışma alanı içerisinde belirlenen beş adet sınıfa ait, her sınıftan 30 adet nokta alımı yapılmak üzere toplamda 150 adet koordinatlı ölçüm yapılmıştır.

Yöntem

Nesne Tabanlı Sınıflandırma Yöntemi

Sınıflandırmanın temel amacı, görüntü üzerindeki anlamlı nesneleri, ait oldukları sınıflara atamaktır. Nesne tabanlı sınıflandırma nesnelere ait spektral bilgiyle birlikte dokusal, mekânsal ve topolojik özellikleri de analizlere dâhil etmektedir. Sadece spektral veriyi kullanmak, görüntü üzerindeki benzer spektral değerlere sahip nesnelerinde, birbirlerinden ayrımı için yeterli olmamaktadır (Cheng ve ark. 2020).

Nesne tabanlı sınıflandırma yönteminin en önemli işlem adımı, görüntünün anlamlı nesnelere ayrıldığı segmentasyon aşamasıdır (Yan ve ark. 2006). Görüntüdeki nesneler farklı özellik, renk, şekil ve boyutlara sahiptirler. Bu nedenle her birinin görüntü üzerinde kapladığı hacim ve büyüklük de farklıdır. Nesnelerin homojen ayrımının yapılabilmesi, doğruluğu direkt etkileyen bir faktördür (Baatz 2000, Benz ve ark. 2004). Nesne tabanlı sınıflandırma yöntemi ve segmentasyon analizleri için geliştirilen farklı yazılımlar ve algoritmalar mevcuttur. Bu çalışmada eCognition yazılımının kullanıcılara sunduğu ve sıklıkla tercih edilen “Çoklu Çözünürlük” algoritmasının kullanılması tercih edilmiştir. Bu algoritma kullanıcılara ölçek, şekil ve bütünlük parametreleri kullanarak, görüntüyü anlamlı nesnelere ayırmalarını sağlamaktadır (Trimble 2012).

Ölçek, segmentasyon doğruluğunu en çok etkileyen parametredir. Parametre seçimi yapılırken görüntü üzerindeki tüm nesnelerin homojen ayrılmasını sağlayacak değerinin seçilmesi gerekmektedir. Çalışmada büyük boyutlu ormanlık alanlar olduğu kadar “Bina” sınıfı ya da “Açık Alan” gibi daha küçük boyutlu nesneler de olduğu için, ölçek parametresinin hassas seçilmesi gerekmektedir. Şekil parametresi, segmentasyon sonrası

oluşacak nesnelerin renk ve şekil kriterleri arasındaki ilişkiyi ifade etmektedir. 0 ile 1 arasında değer alan bu parametre değeri için iki kriter arasında ters yönlü ilişki vardır. Yani şekil kriteri 0.3 iken renk kriteri 0.7 değerini almaktadır. Bütünlük parametresi ise nesnelerin daha yumuşak köşeli ve bütün olmalarını sağlamaktadır. Bu parametre de 0 ile 1 arasında değer alır ve kriterler arası ters yönlü ilişki burada da mevcuttur (eCognition 2011).

Segmentasyondan sonraki aşama sınıflandırmadır. eCognition yazılımı kullanıcılara iki farklı şekilde sınıflandırma yapabilme imkânı sunmaktadır. Bunlardan ilki klasik kontrollü sınıflandırma yöntemi olan, segmentasyon sonrası oluşan anlamlı nesneler üzerinden homojen dağılımla eğitim alanları seçilerek ait oldukları sınıfa tanımlanmasını sağlayan "En Yakın Komşuluk" yöntemidir (Jensen 1996). İkinci sınıflandırma yöntemi ise kullanıcının sınıflara ait tematik özellikler ve eşik değeri belirlemesi ile olan kural tabanlı sınıflandırmadır. Bu özellikler alansal ve konumsal nitelikler olabildiği gibi kullanılan bantlar ve değer aralıklarını da içerebilmektedir. Bu yöntemin ilkinden farkı, kullanıcının segmentasyon sonrası oluşan nesneler üzerinden eğitim alanları seçerek sınıflara atama yapması yerine tanımlanan karar kuralları sayesinde nesnelerin otomatik olarak sınıflara atanmasıdır. Sınıflandırmanın başarısına göre de özellikle yeterli görülmediği durumlarda karar setlerinde ya da eşik değerlerde değişiklikler yapılabilmektedir. Bu çalışmada "En Yakın Komşuluk" sınıflandırma yönteminin kullanılması tercih edilmiştir.

Nesne tabanlı sınıflandırma yönteminin son aşaması ise sınıflandırma doğruluğunun hesaplanmasıdır. Hata matrisi oluşturmak, doğruluk analizi için kullanılan en yaygın yaklaşımdır. Bu noktada arazi verisi, tescilli harita ve paftalar, hava fotoğrafları gibi verilerden yararlanmak da oldukça önemlidir. Hata matrislerinin amacı gerçek dünya nesneleri ile sınıflandırılmış nesnelerin başarısını referans verilerle değerlendirmektir. Hata matrisi ile genel olarak Kullanıcı Doğruluğu (KD), Üretici Doğruluğu (ÜD), Genel Doğruluk (GD) ve Kappa Değeri hesaplanabilmektedir (Yan 2003). KD, sınıflandırılan pikselin o sınıfa gerçekte ne kadar ait olduğunu gösterir. ÜD, piksel veya nesnenin olması gereken gerçek değerinde sınıflandırma yüzdeliğini gösteren değerdir.


GD ise her bir sınıf için doğru sınıflandırılmış piksel ya da nesne sayısının, toplam referans piksel sayısına bölünmesiyle hesaplanmaktadır. 0 ile 1 arasında bir değer alan Kappa Değeri (k)'nin ise 1'e yakınlığı sınıflandırma doğruluğunun başarısını ifade etmektedir (Lillesand ve ark. 2015). Değerlendirme sonrası Kappa değerinin genel doğruluktan küçük olması beklenmektedir.

Global Navigation Satellite System (GNSS)-Küresel Navigasyon Uydu Sistemi

Arazi verisinin referans veri olarak kullanıldığı bu çalışmada ölçme yöntemi olarak, verdiği yüksek doğruluklu konum bilgisi ile GNSS'in kullanılmasına karar verilmiştir. GNSS, TÜBİTAK tarafından geliştirilen, düzenli olarak kodlanmış bilgi yollayan bir uydu ağıdır. GNSS'in dezavantajı, alıcı antenin gökyüzünü açık olarak görmesi gerekliliğidir. Bu gibi durumlarda yani GNSS sistemi en az 4 uyduya gözlem yapamadığında (float solution), doğruluk hassasiyeti de aynı oranda azalmaktadır. Diferansiyel GNSS (DGNSS) denilen bu yöntemle 1-2 metre hassasiyetinde doğruluk elde edilebilmektedir (Kahveci ve ark.2011).

BULGULAR


Nesne tabanlı sınıflandırmayla başlayan uygulama, sınıflandırma sonuçlarının referans alınan arazi verisi ile karşılaştırılmasıyla tamamlanmıştır. Uygulamanın akış diyagramı Şekil 3'te gösterildiği gibidir.



Şekil 3. İş akış diyagramı

Nesne tabanlı sınıflandırmaya ilk olarak “Çoklu Çözünürlük” algoritması kullanılarak segmentasyon parametrelerinin seçimi ile başlanmıştır. Beş farklı sınıf tipinin bulunduğu çalışma alanında büyük objeler olduğu kadar küçük objeler de mevcut olduğundan, deneme-


yanılma yaklaşımı kullanılarak ölçek parametresi 50, şekil parametresi 0.1, bütünlük parametresi de 0.5 olarak belirlenmiştir. Şekil 4’te, seçilen parametreler sonrası görüntü üzerinden sınıflara ait segmentasyon örnekleri, kesitler alınarak gösterilmektedir.



Şekil 4. Segmentasyon sonucu örneği

Segmentasyon parametrelerinin seçiminden sonra “En Yakın Komşuluk” yöntemi ile yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden belirlenen “Yapraklı, İbrelî, Tarım alanı, Açık alan ve Bina” sınıfları için yapılan

nesne tabanlı sınıflandırma sonucu Şekil 5’te gösterilmektedir. Her sınıf türü farklı alan ve büyüklüğe sahip olduğu için örneklem alanları sınıflar için belirli bir adet ile değil, yaklaşık benzer dağılımla seçilmiştir.



Şekil 5. Sınıflandırılmış GeoEye-1 uydu görüntüsü (Bıyıklı 2017)

Sınıflandırma başarısı sayısal olarak, eCognition yazılımında Statistic Type Error Matrix based on Samples yöntemi yani örneklem ya da başka bir ifadeyle eğitim alanlarının seçilmesine dayalı hata matrisi ile yapılmıştır. Bu analiz, segmentasyon sonrası oluşan anlamlı nesneler üzerinden her sınıf için homojen dağılımlı 50’şer adet eğitim alanının seçilmesiyle yapılmıştır. 50’şer adet eğitim alanının seçilmesinin nedeni, “Bina” sınıfının diğer sınıflara oranla alan ve nesne sayısı bakımından daha az olması ve bu sınıf türüne ait görüntü üzerinden homojen dağılımlı seçilebilecek eğitim alanı için yeterli bir sayı olmasıdır. Çizelge 2’de sınıflandırma doğrulukları yüzdelik olarak gösterilmektedir.

Çizelge 2. Nesne tabanlı sınıflandırmaları için doğruluk analizi sonuçları (Bıyıklı 2017)

Sınıflar	En yakın komşuluk		
	ÜD (%)	KD (%)	Kappa
İbrelî	93.58	97.22	0.897
Yapraklı	97.17	88.80	0.963
Tarım alanı	78.57	91.67	0.748
Bina	75.00	81.81	0.744
Açık alan	89.89	81.63	0.873
Genel Doğruluk (%)			90.59
Kappa			0.872

Çizelge 2 incelendiğinde, “İbrelî ve Yapraklı” sınıf türlerinin hem kendi içlerindeki hem de diğer sınıflardan ayrılma başarısının oldukça yüksek olduğu görülmektedir. Diğer sınıflar kendi içlerinde spektral yansıtım değerlerinin benzerliklerinden kaynaklı olarak yanlış sınıflandırılmış olsalar da, %70’in üzerinde doğruluğa sahip oldukları için UA çalışmalarında başarılı kabul edilmektedirler. Özellikle “Bina” sınıfı için hem diğer sınıflara göre çok daha küçük detaylara sahip olmasından hem de eğitim alan sayısının görüntü üzerinde diğer sınıflara oranla daha az sayıda olmasından kaynaklı ÜD’ye göre en düşük doğruluk değerine sahip sınıf olmuştur.

Bundan sonraki uygulama aşaması, arazi çalışması ile devam etmektedir. Arazi çalışması kullanıcılara en güncel veriyi sunabilen bir altlıktır. Sınıflandırma çalışmalarında, bazı durumlarda görüntü üzerinden sınıf ayrımı yapmak zor olabilmektedir. Bu gibi durumlarda görüntüye eşdeğer referans olarak kullanılabilir altlık veri oldukça önemlidir. Hem segmentasyon parametreleri hem eğitim alanlarının seçiminde hem de zamansal değişim gibi değerlendirmeler için çalışma alanına ait arazi çalışmasının yapılması gereklidir. Arazi çalışması 27 Temmuz 2016 tarihinde yapılmış olup, uydu görüntüsü ile aralarında yaklaşık 6 yıllık bir zaman farkı bulunmaktadır. Kentsel alanlarda yıllar arası değişim oldukça fazla olabiliyorken, ormanlık alanlarda bu değişim sık görülen bir durum olmamaktadır. Kastamonu Merkez Orman İşletme Şefliğinden edinilen bilgiye göre bu alana ait herhangi bir çalışma yürütülmediği ancak sınıflar arasında bazı zamansal değişimlerin olabileceği bilgisi edinilmiştir. Elde edilen bu bilgiye ek olarak arazi çalışmasının başlatıldığı tarihe ait, Şekil 6’da gösterilen Google Earth görüntüsü alınarak görsel bir değerlendirme yapılmıştır. Değerlendirme sonucunda Şekil 7’de gösterildiği üzere özellikle orman içi açıklıkların farklı sınıf türleriyle değişim gösterdiği gözlemlenmiştir.




Şekil 6. Çalışma alanına ait 27.07.2016 tarihli Google Earth görüntüsü (Bıyıklı 2017)



Şekil 7. 27.07.2016 tarihli Google Earth görüntüsü ile Geoeye-1 uydu görüntüsü arasındaki zamansal değişimi

Çalışma alanı ormanlık alan içerisinde olduğu için GNSS yeterli uyduyu görememiş ve DGNSS yöntemi ile ölçüm yapılmasına karar verilmiştir. Uydu görüntüsü ve arazi verisinin karşılaştırmasının yapılabilmesi için öncelikle aynı koordinat sisteminde olmaları gerekmektedir. Bunun için de datum ve projeksiyon parametrelerinin benzer olmaları sağlanmalıdır. Datum herhangi bir noktanın yatay ve düşey konumunu belirlemek için alınan referans yüzeyini; projeksiyon ise fiziksel yeryüzünün geometrik bir yüzey üzerine izdüşürülmesini ifade etmektedir. GNSS verileri ITRF96 datumu ve UTM 30 projeksiyonuna sahipken; GeoEye-1 uydu görüntüsü WGS84 datumu ve UTM 60 projeksiyonuna sahiptir. Bir diğer unsur da analizlerin NetCAD v5.2 yazılımında gerçekleştirilebilmesi için GNSS verisinin *.ncn uzantılı dosya verisi hâline getirilmesi gerekliliğidir. Bu işlem için Windows Mobile yazılımı kullanılış olup, sonrasında da NetCAD v5.2 yazılımının kendi içerisinde bulundurduğu dönüşüm parametreleri kullanılarak; arazi verisi, uydu görüntüsünün sahip olduğu datum ve projeksiyon parametresiyle aynı olacak hâle getirilmiştir. Bu şekilde raster veri olan yapay renkli uydu görüntüsü ve sınıflandırılmış görüntü ile arazi verisi olan 150 adet koordinatlı nokta, ilgili CAD yazılımında görsel ve sayısal olarak karşılaştırılabilir duruma gelmiştir. Şekil 8’de araziden alınan 150 adet noktanın, yapay renkli GeoEye-1 uydu görüntüsü üzerindeki dağılımı gösterilmektedir (Bıyıklı 2017).

Koordinatlı arazi verilerinin baz alındığı bu analizde, noktaların sınıflandırılmış görüntü üzerinde denk geldikleri sınıflar Çizelge 3, Çizelge 4, Çizelge 5, Çizelge 6 ve Çizelge 7’de her sınıf için ayrı ayrı verilmiş olup; Çizelge 8’de de tüm sınıf türlerinin nokta bazındaki başarılarının analizi gösterilmiştir (Bıyıklı 2017).



Şekil 8. Araziden alınan noktaların yapay renkli uydu görüntüsü üzerindeki dağılımı

Çizelge 3. İbrelî sınıf türüne ait değerlendirme sonuçları (Bıyıklı 2017)

Sonuç Nokta no	Arazi verisi	Nesne tabanlı sınıflandırma sonucu
1	İbrelî	✓
2	İbrelî	✓
3	İbrelî	✓
4	İbrelî	✓
5	İbrelî	✓
6	İbrelî	✗ (Yapraklı)
7	İbrelî	✓
8	İbrelî	✗ (Yapraklı)
9	İbrelî	✓
10	İbrelî	✓
11	İbrelî	✗ (Yapraklı)
12	İbrelî	✓
13	İbrelî	✗ (Yapraklı)
14	İbrelî	✓
15	İbrelî	✓
16	İbrelî	✓
17	İbrelî	✗ (Açık Alan)
18	İbrelî	✓
19	İbrelî	✓
20	İbrelî	✓
21	İbrelî	✓
22	İbrelî	✓
23	İbrelî	✓
24	İbrelî	✓
25	İbrelî	✓
26	İbrelî	✓
27	İbrelî	✓
28	İbrelî	✓
29	İbrelî	✓
30	İbrelî	✓

Çizelge 4. Yapraklı sınıf türüne ait değerlendirme sonuçları (Bıyıklı 2017)

Sonuç	Arazi verisi	Nesne tabanlı sınıflandırma sonucu
Nokta no		
31	Yapraklı	✗ (İbrelî)
32	Yapraklı	✓
33	Yapraklı	✓
34	Yapraklı	✓
35	Yapraklı	✓
36	Yapraklı	✓
37	Yapraklı	✗ (İbrelî)
38	Yapraklı	✓
39	Yapraklı	✓
40	Yapraklı	✓
41	Yapraklı	✗ (İbrelî)
42	Yapraklı	✓
43	Yapraklı	✓
44	Yapraklı	✓
45	Yapraklı	✓
46	Yapraklı	✓
47	Yapraklı	✓
48	Yapraklı	✓
49	Yapraklı	✓
50	Yapraklı	✓
51	Yapraklı	✗ (İbrelî)
52	Yapraklı	✓
53	Yapraklı	✓
54	Yapraklı	✓
55	Yapraklı	✗ (İbrelî)
56	Yapraklı	✓
57	Yapraklı	✓
58	Yapraklı	✓
59	Yapraklı	✓
60	Yapraklı	✓

Çizelge 5. Tarım alanı sınıf türüne ait değerlendirme sonuçları (Bıyıklı 2017)

Sonuç	Arazi verisi	Nesne tabanlı sınıflandırma sonucu
Nokta no		
61	Tarım Alanı	✓
62	Tarım Alanı	✓
63	Tarım Alanı	✓
64	Tarım Alanı	✓
65	Tarım Alanı	✓
66	Tarım Alanı	✓
67	Tarım Alanı	✓
68	Tarım Alanı	✓
69	Tarım Alanı	✓
70	Tarım Alanı	✗ (Yapraklı)
71	Tarım Alanı	✓
72	Tarım Alanı	✓
73	Tarım Alanı	✗ (Açık Alan)
74	Tarım Alanı	✓
75	Tarım Alanı	✓
76	Tarım Alanı	✓
77	Tarım Alanı	✓
78	Tarım Alanı	✓
79	Tarım Alanı	✓
80	Tarım Alanı	✗ (Açık Alan)
81	Tarım Alanı	✗ (Açık Alan)
82	Tarım Alanı	✗ (Açık Alan)
83	Tarım Alanı	✓

84	Tarım Alanı	✓
85	Tarım Alanı	✓
86	Tarım Alanı	✓
87	Tarım Alanı	✓
88	Tarım Alanı	✓
89	Tarım Alanı	✓
90	Tarım Alanı	✓

Çizelge 6. Açık alan sınıf türüne ait değerlendirme sonuçları (Bıyıklı 2017)

Sonuç	Arazi verisi	Nesne tabanlı sınıflandırma sonucu
Nokta no		
91	Açık Alan	✗ (Tarım Alanı)
92	Açık Alan	✓
93	Açık Alan	✗ (Yapraklı)
94	Açık Alan	✗ (İbrelî)
95	Açık Alan	✗ (Yapraklı)
96	Açık Alan	✓
97	Açık Alan	✗ (İbrelî)
98	Açık Alan	✓
99	Açık Alan	✗ (İbrelî)
100	Açık Alan	✓
101	Açık Alan	✓
102	Açık Alan	✓
103	Açık Alan	✓
104	Açık Alan	✓
105	Açık Alan	✓
106	Açık Alan	✗ (Tarım Alanı)
107	Açık Alan	✓
108	Açık Alan	✓
109	Açık Alan	✓
110	Açık Alan	✗ (Tarım Alanı)
111	Açık Alan	✓
112	Açık Alan	✗ (Tarım Alanı)
113	Açık Alan	✓
114	Açık Alan	✓
115	Açık Alan	✗ (Yapraklı)
116	Açık Alan	✓
117	Açık Alan	✗ (İbrelî)
118	Açık Alan	✗ (Yapraklı)
119	Açık Alan	✗ (İbrelî)
120	Açık Alan	✗ (Yapraklı)

Çizelge 7. Bina sınıf türüne ait değerlendirme sonuçları (Bıyıklı 2017)

Sonuç	Arazi verisi	Nesne tabanlı sınıflandırma sonucu
Nokta no		
121	Bina	✓
122	Bina	✓
123	Bina	✓
124	Bina	✓
125	Bina	✗ (Açık Alan)
126	Bina	✓
127	Bina	✗ (Tarım Alanı)
128	Bina	✗ (Tarım Alanı)
129	Bina	✗ (Tarım Alanı)
130	Bina	✓
131	Bina	✓
132	Bina	✓
133	Bina	✓
134	Bina	✓
135	Bina	✗ (Tarım Alanı)

136	Bina	X(Tarım Alanı)
137	Bina	X(Tarım Alanı)
138	Bina	X(Tarım Alanı)
139	Bina	✓
140	Bina	✓
141	Bina	✓
142	Bina	✓
143	Bina	✓
144	Bina	X(Açık Alan)
145	Bina	X(Tarım Alanı)
146	Bina	✓
147	Bina	X(Tarım Alanı)
148	Bina	✓
149	Bina	✓
150	Bina	✓

Çizelge 8. Tüm sınıf türlerinin arazi verisi ile nokta bazında karşılaştırılması (%)

Sınıf türü	Arazi sonuçları	Nesne tabanlı sınıflandırma sonucu
Sonuç		
İbrelî (%)	100	83
Yapraklı (%)	100	83
Tarım alanı (%)	100	83
Açık alan (%)	100	53
Bina (%)	100	63

Nesne tabanlı sınıflandırma sonuçlarının jeodezik yöntemle yapılan arazi çalışması ile karşılaştırılmasının yapıldığı bu çalışma sonrasında, sonuçları desteklemek adına literatürde yapılan benzer çalışmalar incelenmiştir. Ceylan ve Uysal (2019) ağaçlık alanların sınıflandırılması için İnsansız Hava Araçları (İHA)'ndan yararlanarak nesne tabanlı sınıflandırma ile obje çıkarımı yapmışlardır. İHA'lardan elde ettikleri görüntü verisinin fotogrametrik değerlendirme sürecinde YKN'leri GNSS yöntemi ile ölçmüşlerdir. Segmentasyon parametrelerinin de hassas bir şekilde belirlenmesi ile yürütülen bu çalışmada, jeodezik ölçümden elde edilen yeterli konum doğruluğu ile de başarılı bir sınıflandırma sonucu elde edilmiştir. Zeybek ve Şanlıoğlu (2019)'nun topoğrafik yüzey değişimlerinin izlenmesi ve Hamal ve Ulvi (2022)'nin 3B kent modelleri oluşturma süreci için benzer yöntem teknik kullanılarak yürüttükleri çalışmalarda da başarılı sonuçlar elde edilmiştir. Özellikle görüntü verisinin İHA olduğu çalışmalarda ortorektifiye işlemi için kullanılan GNSS yönteminden elde edilen hassas sonuçların; uydu görüntüleriyle yapılan çalışmalar içinde ek veri olarak kullanılabilir olduğunu göstermiştir. GNSS ölçümlerinin gerçeğe yakın konumsal verinin üretilmesinde ve sınıflandırma çalışmaları içinde görüntü verilerinin

oluşturulmasında kullanılabilir oldukları buradan çıkarılacak bir başka sonuçtur. Teke ve ark. (2016)'nın akıllı tarım fizibilitesi kapsamında İHA ve çeşitli uydu görüntüleri kullanarak ve yersel ölçümler ile de uygulamalarını destekledikleri çalışmalarında hem İHA için fotogrametrik değerlendirmede hem de yersel ölçümler için GNSS ölçme yöntemini kullanmışlardır. GNSS ölçümlerinin gerçeğe yakın konumsal verinin üretilmesinde ve sınıflandırma çalışmaları içinde görüntü verilerinin oluşturulmasında kullanılabilir oldukları bu çalışma ile de gösterilmiştir.

SONUÇLAR VE ÖNERİLER

Kastamonu ili Merkez Orman İşletme Şefliği'ne ait sahada belirlenen 12x12 km'lik çalışma alanı için ilk olarak "Yapraklı, İbrelî, Tarım alanı, Açık alan ve Bina" sınıfları için nesne tabanlı sınıflandırma ile detay çıkarımı yapılmış olup, sonrasında arazi çalışması ile uygulamaya devam edilmiştir. Çalışmanın ilk aşamasında yapılan nesne tabanlı sınıflandırma sonuçlarına bakıldığında orman örtü tipleri olan "Yapraklı ve İbrelî" sınıf türlerindeki ayrımın oldukça başarılı yapıldığı görülmektedir. "Tarım alanı, Açık alan ve Bina" sınıflarında ise spektral yansıma değerlerinin benzerliğinden kaynaklı yanlış sınıflandırmanın yapıldığı sayısal olarak sonuçlara da yansımıştır. Segmentasyon parametrelerinin özellikle ölçek parametresinin, geniş ormanlık örtü tiplerine rağmen özellikle "Bina ve Açık alan" gibi daha küçük boyutlu nesneler için oldukça hassas seçilmesine rağmen, detay çıkarım başarısı "Yapraklı ve İbrelî" sınıf türleri kadar başarılı olamasa da, %90.59 genel doğruluk değeri oldukça başarılı bir sınıflandırma sonucu olmuştur. Orman örtü tipleri ile çalışmalar yapılırken, bünyelerinde bulunan klorofilin yakın kızılötesi bölgede çok az soğurulmalarından kaynaklı kullanılan uydu görüntüsünün yüksek çözünürlüklü olmasının yanı sıra, bu banda sahip olması da gerekmektedir. GeoEye-1 uydu görüntüsünün yüksek çözünürlüklü olması ormancılık çalışmaları için bir yandan da dezavantaj olabilmektedir. Çözünürlüğün artması spektral varyansı da artırmakta ve bu da detay çıkarımını olumsuz etkilemektedir. Bu çalışmada orman örtü tipini ifade eden iki sınıfta yüksek başarı ile sınıflandırılmış olması, bu tuz-biber etkisinin sonuçları olumsuz etkilemediğini ve bu alanda yapılacak

çalışmalar için de GeoEye-1 uydu görüntüsünün kullanılabilirliğini göstermiştir. Arazi verisinin baz alınarak yapıldığı uygulamada, yine “Açık alan ve Bina” sınıflarında düşük başarılı sonuçlar elde edilmiştir. Sınıfların karşılaştırma başarısı incelendiğinde özellikle dar alan ve küçük boyutlara sahip nesnelerin, ölçüm ve dönüşümden kaynaklı doğruluk hassasiyetinden olumsuz etkilenebildikleri gözlemlenmiştir. Veriler arası kayıklık, bu gibi nesneler ve alanlarda, nokta bazlı değerlendirme analizi olumsuz etkileyebilmektedir. Bununla birlikte referans veri için nokta alım sayısı da doğruluğu oldukça etkileyen bir faktördür. Çalışma alanının yoğun ormanlık alanı kapsamı istenilen her alandan nokta alımını zorlaştırmış olduğu için 30 adet ile sınırlı kalınmıştır. Arazi verisi ile yapılan analizlerde bu durumun etkileri de sonuçlara yansımıştır. Uydu ve arazi verisi arasındaki zamansal farklılıklar az miktarlarda da olsa, sonuçları olumsuz etkileyebileceği görülmüştür. Tüm bu durumlara rağmen özellikle orman örtü tiplerinin analizinde %83'lük bir başarı oldukça yüksektir. Konumsal çözünürlüğü uydu görüntüsüne göre oldukça yüksek olan arazi verisinin yanı sıra nesne tabanlı sınıflandırma yönteminin de zamansal değişimler için gerçeğe yakın sonuçlar vermiş olması bu çalışmadan elde edilen önemli bir sonuç ve gelecek çalışmalar için kullanılabilirliği de bir öneri olmuştur.

TEŞEKKÜR

Bu çalışma sorumlu yazarın “Yüksek Çözünürlüklü Görüntü Verileri Kullanarak Ormanlık Alanlarda Sınıflandırma Uygulamaları” başlıklı yüksek lisans tezinden üretilmiştir. Çalışmada kullanılan, radyometrik ve geometrik düzeltilmeleri yapılmış GeoEye-1 uydu görüntüsünün temini için Kastamonu Üniversitesi Orman Fakültesi hocalarına ve çalışma alanı ile ilgili bilgilerini esirgemedikleri için Kastamonu Merkez Orman İşletme Şefliği çalışanlarına teşekkürlerimizi sunarız.

KAYNAKLAR

Ahady AB, Kaplan G (2022) Classification comparison of Landsat-8 and Sentinel-2 data in Google Earth Engine, study case of the city of Kabul. *International Journal of Engineering and Geosciences*, 7(1): 24-31.
Aksoy B, Ercanoglu M (2012) Landslide identification and classification by object-based image analysis and fuzzy logic: an example from the Azdavay region (Kastamonu, Turkey). *Computers & Geosciences*, 38(1): 87-98.

Apaydın C, Abdikan S (2021) Fındık bahçelerinin Sentinel-2 verileri kullanılarak piksel tabanlı sınıflandırma yöntemleriyle belirlenmesi. *Geomatik*, 6(2): 107-114.
Avcı C, Budak M, Yağmur N, Balçık F (2023) Comparison between random forest and support vector machine algorithms for LULC classification. *International Journal of Engineering and Geosciences*, 8(1): 1-10.
Baatz M (2000) Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung*, 12-23.
Bayramoğlu Z, Uzar M (2023) Performance analysis of rule-based classification and deep learning method for automatic road extraction. *International Journal of Engineering and Geosciences*, 8(1): 83-97.
Belgiu M, Drăguț L (2016) Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114: 24-31.
Benz UC, Hofmann P, Willhauck G, Lingenfelder I, Heynen M (2004) Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry and Remote Sensing*, 58 (3-4): 239-258.
Bıyıklı D (2017) Yüksek çözünürlüklü görüntü verileri kullanarak ormanlık alanlarda sınıflandırma uygulamaları. Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi, Zonguldak.
Blaschke T (2010) Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1): 2-16.
Blaschke T, Lang S, Hay G (Eds.) (2008) Object-based image analysis: spatial concepts for knowledge-driven remote sensing applications. Springer Science & Business Media.
Ceylan MC, Uysal M (2019) İnsansız hava araçlarından üretilen verilerin değerlendirilmesi ve ağaçlık alanların sınıflandırılması. *Türkiye İnsansız Hava Araçları Dergisi*, 1(1): 1-6.
Chen G, Thill JC, Anantsuksomsri S, Tontisirin N, Tao R (2018) Stand age estimation of rubber (*Hevea brasiliensis*) plantations using an integrated pixel-and object-based tree growth model and annual Landsat time series. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144: 94-104.
Cheng, G, Xie X, Han J, Guo L, Xia GS (2020) Remote sensing image scene classification meets deep learning: challenges, methods, benchmarks, and opportunities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13: 3735-3756.
Çömert R (2020) İnsansız hava aracı verilerinden nesne tabanlı sınıflandırma yaklaşımı ile siğ heyelanların tespiti. *Anadolu Üniversitesi Doktora Tezi*, Eskişehir.
Dou J, Chang KT, Chen S, Yunus AP, Liu JK, Xia H, Zhu Z (2015) Automatic case-based reasoning approach for landslide detection: integration of object-oriented image analysis and a genetic algorithm. *Remote Sensing*, 7(4): 4318-4342.
Doxani G, Karantzalos K, Tsakiri-Strati M (2015) Object-based building change detection from a single multispectral image and pre-existing geospatial information. *Photogrammetric Engineering & Remote Sensing*, 81(6): 481-489.
Dragozi E, Gitis IZ, Stavrakoudis DG, Theocharis JB (2014) Burned area mapping using support vector machines and the FuzCoC feature selection method on VHR IKONOS imagery. *Remote Sensing*, 6(12): 12005-12036.
eCognition (2011) Trimble Documentation. eCognition Developer 8.7 User Guide, München, Germany, 258pp.

- Ersoy E, Yılmaz KT, Atak BK, Gülçin D (2019) Sentinel-2A uydu görüntüsünde nesne tabanlı sınıflandırma yöntemi kullanılarak kıyı habitatlarının haritalanması. Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 19(1): 152-161.
- Hamal SNG, Ulvi A (2022) 3B Kent Modelleri oluşturma sürecinde İHA fotogrametrisi ve CBS entegrasyonu: Mersin Üniversitesi Çiftlikköy Kampüsü Örneği. Türkiye Coğrafi Bilgi Sistemleri Dergisi, 4(2): 97-105.
- Haralick RM, Shapiro LG (1985) Image segmentation techniques. Computer Vision, Graphics, and Image Processing, 29(1): 100-132.
- Heinl M, Walde J, Tappeiner G, Tappeiner U (2009) Classifiers vs. input variables—the drivers in image classification for land cover mapping. International Journal of Applied Earth Observation and Geoinformation, 11(6): 423-430.
- Jensen JR (1996) Introductory Digital Image Processing: A Remote Sensing Perspective (No. Ed. 2). Prentice-Hall Inc.
- Kabadayı A, Uysal M (2020) Çok yüksek çözünürlüklü İHA verilerinden bina tespiti. Türkiye İnsansız Hava Araçları Dergisi, 2(2): 43-48.
- Kavzoglu T, Tonbul H (2018) An experimental comparison of multi-resolution segmentation, SLIC and K-means clustering for object-based classification of VHR imagery. International Journal of Remote Sensing, 39(18): 6020-6036.
- Kavzoglu T, Tonbul H, Çölkesen İ, Sefercik UG (2021) The use of object-based image analysis for monitoring 2021 marine mucilage bloom in the sea of Marmara. International Journal of Environment and Geoinformatics, 8(4): 529-536.
- Köhl M, Magnussen S, Marchetti M (2006) Sampling methods, remote sensing and GIS multiresource forest inventory. (Vol. 2). Heidelberg: Springer.
- Li X, Myint SW, Zhang Y, Galletti C, Zhang X, Turner II BL (2014) Object-based land-cover classification for metropolitan Phoenix, Arizona, using aerial photography. International Journal of Applied Earth Observation and Geoinformation, 33: 321-330.
- Lillesand T, Kiefer RW, Chipman J (2015) Remote sensing and Image Interpretation. John Wiley & Sons.
- Lu D, Weng Q (2007) A survey of image classification methods and techniques for improving classification performance. International Journal of Remote Sensing, 28(5): 823-870.
- Ma L, Li M, Ma X, Cheng L, Du P, Liu Y (2017) A review of supervised object-based land-cover image classification. ISPRS Journal of Photogrammetry and Remote Sensing, 130: 277-293.
- Machala M, Zejdová L (2014) Forest mapping through object-based image analysis of multispectral and LiDAR aerial data. European Journal of Remote Sensing, 47(1): 117-131.
- Marangoz AM (2009) Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve CBS Ortamında Bütünleştirilmesi. Yıldız Teknik Üniversitesi FBE Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı Uzaktan Algılama ve CBS Programında Hazırlanan Doktora Tezi, İstanbul.
- Mitri GH, Gitas IZ (2004) A semi-automated object-oriented model for burned area mapping in the Mediterranean region using Landsat-TM imagery. International Journal of Wildland Fire, 13(3): 367-376.
- Myint SW, Gober P, Brazel A, Grossman-Clarke S, Weng Q (2011) Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. Remote Sensing of Environment, 115(5): 1145-1161.
- Pal NR, Pal SK (1993) A review on image segmentation techniques. Pattern Recognition, 26(9): 1277-1294.
- Saraloğlu E (2021) pankromatik bandın piksel tabanlı sınıflandırmaya etkisi. Turkish Journal of Remote Sensing and GIS, 2(1): 32-40.
- Sefercik UG, Kavzoglu T, Çölkesen İ, Nazar M, Öztürk MY, Adalı S, Dinç S (2023) 3D positioning accuracy and land cover classification performance of multispectral RTK UAVs. International Journal of Engineering and Geosciences, 8(2): 119-128.
- Sevgen SC (2019) Airborne lidar data classification in complex urban area using random forest: a case study of Bergama, Turkey. International Journal of Engineering and Geosciences, 4(1): 45-51.
- Teke M, Devci HS, Öztoprak F, Efendioğlu M, Küpçü R, Demirkessen C, Demirpolat C (2016) Akıllı tarım fizibilite projesi: hassas tarım uygulamaları için havadan ve yerden veri toplanması, işlenmesi ve analizi. 6. Uzaktan Algılama-CBS (UZAL-CBS), 5-7 Ekim 2016, Ankara.
- Tırmanoğlu B, İsmailoğlu İ, Kocal AT, Musaoğlu N (2023) Yeni nesil multispektral ve hiperspektral uydu görüntülerinin arazi örtüsü/arazi kullanımı sınıflandırma performanslarının karşılaştırılması: Sentinel-2 ve PRISMA Uydusu. Geomatik, 8(1): 79-90.
- Trimble (2012) eCognition developer user guide. Trimble Germany GmbH, München, 261 pp.
- Tso B, Mather P (2009) Classification methods for remotely sensed data. Danvers.
- URL-1:http://www.nik.com.tr/content_sistem_uydu.asp?id=12, Erişim tarihi: 02.04.2023.
- Wells WK (2010) Object-based segmentation and classification of one meter imagery for use in forest management plans. Utah State University.
- Xu X, Shi Z (2017) Multi-objective based spectral unmixing for hyperspectral images. ISPRS Journal of Photogrammetry and Remote Sensing, 124: 54-69.
- Yan E, Wang X, Huang J (2006) Concept and classification of coarse woody debris in forest ecosystems. Frontiers of Biology in China, 1: 76-84.
- Yan G (2003) Pixel based and object oriented image analysis for coal fire research. Enschede, The Netherlands: ITC.
- Yılmaz OS, Gülsen F, Güngör R, Kadı F (2018) Coğrafi bilgi sistemleri ve uzaktan algılama teknikleri ile arazi kullanım değişiminin incelenmesi, Köprübaşı İlçesi Örneği. Geomatik, 3(3): 233-241.
- Yiğit AY, Uysal M (2019) Nesne tabanlı sınıflandırma yaklaşımı kullanılarak yolların tespiti. Türkiye Fotogrametri Dergisi, 1(1): 17-24.
- Zeybek M, Şanlıoğlu İ (2019) Topoğrafik yüzey değişimlerinin görüntü işleme teknikleriyle belirlenmesi üzerine bir araştırma. Doğal Afetler ve Çevre Dergisi, 5(2): 350-367.
- Zhang L, Jia K, Li X, Yuan Q, Zhao X (2014) Multi-scale segmentation approach for object-based land-cover classification using high-resolution imagery. Remote Sensing Letters, 5(1): 73-82.