

GeoEye-1 Uydu Görüntüsü Kullanarak Ormanlık Alanların Nesne Tabanlı Sınıflandırma Yöntemi ile Analizi: Kastamonu İli Örneği

Duygu BIYIKLI^{1*}, Aycan Murat MARANGOZ²

Öz

Uzaktan algılama teknolojilerinin gelişmesi, farklı analiz yöntemleri ve yazılımlar sayesinde uydu görüntüleri üzerinden nesnelerin yüksek doğrulukla sınıflandırılmaları mümkündür. Bu çalışmada, Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliğine ait 12X12 km'lik çalışma alanının, 3 Eylül 2011 tarihinde çekilmiş yüksek çözünürlüklü GeoEye-1 uydu görüntüsü kullanılarak, arazi örtü tipleri ve diğer sınıf türlerine ait sınıflandırma başarıları incelenmiştir. Genel doğruluk değeri %90.59 olurken kappa değeri ise 0.872 olarak bulunmuştur. eCognition yazılımı ile nesne tabanlı sınıflandırma yöntemi kullanılarak elde edilen yüksek doğruluklu sınıflandırılmış görüntü sonrası, 1/25000 ölçekli raster veri olan meşcere haritası NetCAD v5.2 yazılımı ile vektör veri haline getirilerek karşılaştırmalar için altlık olarak hazırlanmıştır. Uygulamanın devamında GeoEye-1 uydu görüntüsü elle vektörleştirilerek, sınıflandırma sonuçları ve meşcere haritasına ait vektör veri ile hem görsel hem de sayısal olarak karşılaştırılmıştır. Çalışmanın sonucunda ormancılık faaliyetlerinde kullanılan meşcere haritasının, hem büyük ölçekli hem konumsal çözünürlüğünün düşük olması hem de sadece orman örtü tipleri gibi geniş alanlara sahip sınıf türlerini göstermesinden kaynaklı, nesnelerin hassas sınıflandırılmaları için yeterli olmadığı sonucu elde edilmiştir. Görsel ve sayısal olarak yüksek doğrulukla elde edilen sınıflandırılmış GeoEye-1 uydu görüntüsü ile ormancılık alanında meşcere haritalarının yerine rahatlıkla kullanılabileceği de gösterilmiştir.

Anahtar Kelimeler: Nesne tabanlı sınıflandırma, eCognition yazılımı, Meşcere haritası, GeoEye-1 uydu görüntüsü, NetCAD v5.2 yazılımı.

Analysis of Forest Areas by Object-Based Classification Method Using GeoEye-1 Satellite Image: A Case Study of Kastamonu Province

Abstract

Thanks to the development of remote sensing technologies, different analysis methods, and software, it is possible to classify objects with high accuracy over satellite images. In this study, classification successes of land cover types and other class types were investigated by using a high resolution GeoEye-1 satellite image taken on September 3, 2011, of the 12X12 km study area belonging to Kastamonu Regional Directorate of Forestry, Central Operations Directorate. While the overall accuracy value was 90.59%, the kappa value was found to be 0.872. After the high-accuracy classified image obtained by using the object-based classification method with eCognition software, the stand map with 1/25000 scale raster data was converted into vector data with NetCAD v5.2 software and prepared as a base for comparisons. In the continuation of the application, the GeoEye-1 satellite image was vectorized manually and compared both visually and numerically with the classification results and the vector data of the stand map. As a result of the study, it was concluded that the stand map used in forestry activities is not sufficient for the precise classification of objects, since it shows both large-scale and low spatial resolution and only shows class types with large areas such as forest cover types. It has also been shown that the classified GeoEye-1 satellite image obtained with high visual and numerical accuracy can be easily used instead of stand maps in the field of forestry.

Keywords: Object-Based classification, eCognition software, Stand type maps, Geoeeye-1 satellite image, NetCAD V5.2 software.

¹Kastamonu Üniversitesi, İhsangazi Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Kastamonu, Türkiye, dbiyikli@kastamonu.edu.tr

²Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü, Zonguldak, Türkiye, aycanmarangoz@hotmail.com

¹<https://orcid.org/0000-0002-0220-5101>

²<https://orcid.org/0000-0003-4409-6000>

1. Giriş

Uzaktan Algılama (UA) teknolojileri ve sayısal görüntü işleme tekniklerinin gelişmesiyle birlikte yüksek çözünürlüklü uydu görüntüleri üzerinden arazi örtüsü ile ilgili detay çıkarımı ve analiz yapmak oldukça kolaylaşmıştır. Arazi örtüsü zamansal olarak değişiklik göstermektedir. Hem kentsel hem de kırsal alanlarda görüntü üzerindeki her bir nesnenin değişimi çeşitli tekniklerle birlikte gerçeğe çok yakın sonuçlar verecek şekilde tespit edilebilmektedir (Lillesand ve ark., 2015). Değişim, nesnelerin Coğrafi Bilgi Sistemleri (CBS) tabanlı çeşitli yazılımlar sayesinde sınıflandırılmaları ile analiz edilebilmektedir. Algılayıcı teknolojilerinin gelişmesi ile birlikte ormancılık, tarım, ulaşım, peyzaj, arsa ve arazi düzenleme gibi birçok nitelikli veri üzerinden anlamlı nesnelere çıkarılabilmektedir. Sınıflandırmanın temel mantığı, benzer spektral yansıma değerine sahip nesnelerin belirlenerek aynı sınıfa dâhil edilmesine dayanmaktadır. Günümüzde çeşitli sınıflandırma yöntemleri mevcut olmakla birlikte, literatürde en sık kullanılan piksel ve nesne tabanlı sınıflandırma yöntemleridir (Çölkesen ve Kavzaoğlu, 2017).

Piksel tabanlı sınıflandırma tekniği, görüntüdeki nesnelere ait sadece spektral değerleri dikkate alarak sınıflandırma yapan bir tekniktir. Sadece spektral değerlerin kullanılması çoğu zaman, benzer ya da yakın spektral değerlere sahip nesnelerin yanlış sınıflandırmasına da neden olmaktadır (Blaschke, 2010). Bu yaklaşıma ek olarak konumsal verilerin de sınıflandırmaya dâhil edilmesinin sınıflandırma doğruluğunu artıracak düşünülerek, nesne tabanlı sınıflandırma yöntemi geliştirilmiştir. Sınıflandırmada amaç görüntü üzerindeki nesnelerin gerçek dünyaya en yakın hâliyle analizinin yapılmasıdır. Bu nedenle piksel tabanlı sınıflandırma yöntemi yeterli olmamakla birlikte, nesne tabanlı sınıflandırma yönteminin kullanılması daha gerçek sonuçların elde edilmesini sağlamaktadır. Piksel tabanlı sınıflandırma, arazi üzerindeki her türlü nesneyi piksel bazında değerlendirerek, nesnenin atanacağı sınıfı sadece spektral benzerlikle değerlendiren yöntemdir. Algılayıcı teknolojileri her ne kadar gelişmiş olsa da bu durum yöntemin yüksek doğruluklu sınıflandırma sonucu elde etmesini sağlayamamaktadır (Holland ve ark., 2006).

Nesne tabanlı sınıflandırma tekniği ise, ekolojik ve coğrafi gibi çevre disiplinlerini de analizlere dâhil eden bir yöntemdir (Blaschke ve Strobl 2001). Bu yöntemin en önemli işlem adımı segmentasyondur. Segmentasyon görüntünün anlamlı nesnelere ayrılmasını sağlayan ve sınıflandırma doğruluğunu en çok etkileyen aşamadır. Doğru parametrelerin kullanılarak yapıldığı sınıflandırma her zaman gerçeğe yakın sonuçlar vermektedir. Bu nedenle ölçek, şekil ve bütünlük parametreleri, hem görüntüye hem de sınıflandırılacak nesnelere en uygun şekilde belirlenmelidir (Yan ve ark., 2006). Segmentasyon homojenliği ifade ederken, amaç segmentlerdeki heterojenliği en aza indirmektir. Görüntü üzerinde milyonlarca pikselle sınıflandırma sonucu elde etmek yerine, nesnelere konumsal ve spektral olarak doğru bir şekilde yansıtacak segmentler oluşturmak, çok daha

anlamalı nesnelere elde edilmesini sağlamaktadır. Sınıflandırma aşamasında kullanıcının, segmentasyon sonrası homojen bir şekilde seçtiği nesnelere, gerekli sınıflara ataması gerekmektedir (Baatz ve ark., 2004).

UA teknolojilerinin gelişmesi ile her ne kadar yüksek çözünürlüklü görüntüler elde edilse de ormanlık alanların analizi için düşük çözünürlüklü görüntülerin kullanılmasının daha olumlu sonuçlar verdiği ortaya çıkmıştır. Spektral varyansın yüksek olması; sınıflandırma için avantaj sayılırken, ormanlık alanlarda ki sınıfların belirlenmesinde bu durum özellikle ağaç türlerinin ayrımını oldukça zorlaştırmıştır (Shaban ve Dikshit, 2001).

Bu çalışmada, 2011 tarihli GeoEye-1 uydu görüntüsü kullanarak Kastamonu ili Merkez Orman İşletme Şefliğine ait sınırlar içerisinde çalışma alanı belirlenerek, “İbrelî, Yapraklı, Açık alan, Tarım alanı ve Bina” olmak üzere beş farklı sınıf için nesne tabanlı sınıflandırma analizi gerçekleştirilmiştir. Sınıflandırma eCognition yazılımı kullanılarak yapılmış olup, sınıflandırma sonrası sonuçlar veri hâline getirilmiştir. Uygulamada kullanılan GeoEye-1 uydu görüntüsü elle vektörleştirilerek; sınıflandırma sonrası ve 1/25000 ölçekli meşcere haritasının sayısallaştırılması ile elde edilen vektör veri ile karşılaştırılmıştır. GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası, raster ve vektör veri yapısını bünyesinde bulunduran NetCAD v5.2 yazılımı ile sayısallaştırılmıştır. Hem görsel hem de sayısal olarak yapılan analizler ile verilerin üstünlük ve eksikleri değerlendirilmiştir.

Çalışmanın literatüre sağlayacağı katkı ve özgünlüğü ise, nesne tabanlı sınıflandırma yönteminin farklı arazi örtüleri barındıran ormanlık alanlar için, manuel müdahale olmadan, algoritmalar sayesinde otomatik olarak çıkarımının yüksek doğrulukla yapıldığını göstermek kadar geçmiş tarihli meşcere haritalarının kullanımının da nesne çıkarımındaki etkilerini göstermek olmuştur. Ormanlık alanlarda yapılan çalışmalarda kullanılan tescilli 1/25000 ölçekli meşcere haritalarının güncel ve küçük boyutlu nesne ve alanları yansıtmadığını göstermek çalışmanın önemli ve özgün sonuçlarından birisidir. Uydu görüntüsünün alındığı tarihle, meşcere haritasının tescil tarihlerinin farklı olması arazi örtüsünde meydana gelen değişimi de zamansal olarak ortaya çıkarmıştır. Sınıflandırma başarısının yüksek doğrulukla elde edilmesi sonrası, elle vektörleştirilen uydu görüntüsü ile karşılaştırılması da; aynı veri üzerinde çalışılmasına rağmen spektral yansıma değerlerinin bazı sınıflarda yanlış çıkarıma neden olduğunu göstererek, kullanıcının sınıflandırma öncesi referans ek veriler kullanarak daha çok eğitim ve veri seti seçmesi gerekliliğini de göstermiştir.

2. Materyal ve Metot

Orman ağaçlarının yoğun olarak bulunduğu Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliği sınırları içerisinde ki 24 320 ha alanda, 12 X 12 km’lik bir çalışma alanı belirlenmiştir. Seçilen alan içerisinde orman örtü tipleri haricinde farklı sınıfların olmasına da dikkat edilmiştir.

Farklı sınıf çeşitliliği, orman örtü tiplerinin kendi içerisindeki sınıflandırma başarısı kadar, diğer sınıflardan da ayırt edilebilme başarısını göstermek için önemlidir.

Çalışmada iki farklı veri kullanılmıştır. Bunlardan ilki yüksek çözünürlüklü GeoEye-1 uydu görüntüsü iken, bir diğeri 1/25000 ölçekli meşcere haritasıdır. GeoEye-1 uydu görüntüsü hem nesne tabanlı sınıflandırma hem de elle vektörleştirilerek analizler için kullanılmıştır. Meşcere haritası ormancılık faaliyetlerinde kullanılan, genel arazi örtüsünü çok küçük detaylar haricinde gösteren 1/25000 ölçekli bir haritadır. Bu iki veri ile analizlerin gerçekleştirilmesinin nedeni, ormancılık alanında kullanılan meşcere haritalarının, yeryüzünden oldukça uzun mesafelerden alınan uydu görüntüleri ve sınıflandırma tekniği ile karşılaştırılarak, birbirlerinin yerine kullanımlarının avantaj ve dezavantajlarının gösterilmesi için olmuştur. GeoEye-1 uydusu Tablo 1’de gösterildiği üzere 0.41 m pankromatik ve 1.65 m multispektral bantlarla yüksek konumsal ve spektral çözünürlüğe sahiptir. Şekil 1’de ise çalışma alanına ait 3 Eylül 2011 tarihinde alınan GeoEye-1 uydu görüntüsü gösterilmektedir. Atıldığı 6 Eylül 2008 tarihinden beri dünyanın en yüksek çözünürlüklü ticari gözlem uyduları arasındadır (URL-1). Görüntü verisi, Sayısal Yüksel Modeli (SYM) üzerinden 32 YKN seçilerek, 8 cm konumsal doğrulukla üretilmiştir.

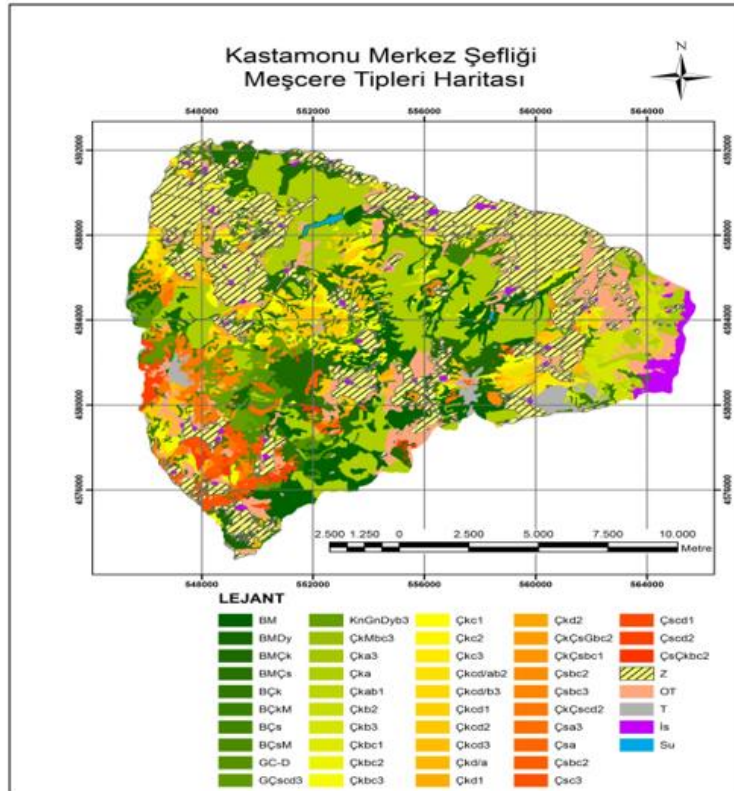
Tablo 1. GeoEye-1 uydu görüntüsünün teknik özellikleri (URL-1).

Yersel Çözünürlük (Pan/MS)	0.41 m/1.65 m
Spektral Çözünürlük (Pan/MS)	450-800 nm (pankromatik)
	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 Aralık	11 bit
Uydu Ömrü-Tahmini	10 yıldan fazla
Yeniden Geçiş Aralığı	3 günden az
Yörüngesel Yüksekliği	681 km
Nodal Crossing	10.30 sabah




Şekil 1. Çalışma alanının yüksek çözünürlüklü Geoeye-1 uydusuna ait görüntüsü.

Ölçeği gereği fazla detay içermeyen, büyük alanlara sahip arazi ve orman örtülerini gösteren meşcere haritaları, ormancılık uygulamalarının hemen her aşamasında kullanılan önemli bir kaynaktır. Bu çalışmada kullanılan, Kastamonu Merkez Orman İşletme Şefliğine ait 1999 yapım tarihli meşcere haritası Şekil 2’de gösterilmektedir.



Şekil 2. Kastamonu Merkez Orman İşletme Şefliğine ait meşcere haritası.

Ormancılık çalışmalarında doğal renkli görüntü yerine bant sıralaması değiştirilerek yer örtü tiplerinin birbirlerinden daha belirgin ayrılmasını sağlayan kızılötesi bantın sahip olduğu uydu görüntüleri kullanılmaktadır. GeoEye-1 görüntüsünün, ormancılık çalışmaları için büyük önem taşıyan 700 nm dalga boyundan sonraki kesime ait duyarlı yakın kızılötesi banta sahip olması uygulama için yeterli olmuştur. Yeşil bitkiler yapılarında buldukları klorofil nedeniyle, yakın kızıl ötesi bölgede az miktarda soğurularak büyük yansımaya değerlerine sahip olurlar. Klorofilin azalması yansımaya değerinin de azalacağı anlamına gelmektedir. Bu nedenle özellikle bitki örtüsünü içeren çalışma alanları için görüntünün alındığı iklim ve mevsim oldukça önemlidir. Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü Eylül ayında alınmış olmasına rağmen, bu tarihte ormanlık alanda bulunan ve çalışmadaki “İbrelili ve Yapraklı” sınıf türlerinin değişime uğramaması, yansımaya değerleri ve ayırt edilebilirlikleri için olumsuz bir durum yaratmamıştır. Şekil 3’te doğal renkli GeoEye-1 uydu görüntüsünün bant sıralamasının değiştirilmesiyle elde edilen yapay renkli görüntü gösterilmektedir.



Şekil 3. Çalışma alanına ait yapay renkli GeoEye-1 uydu görüntüsü.

Çalışmada kullanılan uydu görüntüsü ve meşcere haritası üzerinden uygulamalara başlamak için üç farklı yazılım kullanılmıştır. GeoEye-1 uydu görüntüsünün nesne tabanlı sınıflandırılması ve vektörleştirilmesi için eCognition Developer 9.1, vektörleştirilen verinin sınıf türlerine ayrıştırılması ve CAD ortamında kullanımının hazır hâle getirilmesi için ArcGIS 9.3.1, uydu görüntüsünün elle vektörleştirilmesi, 1/25000 ölçekli meşcere haritasının sayısallaştırılması için de NetCAD v5.2 yazılımı kullanılmıştır. Ayrıca tüm vektörel sonuçların hem görsel hem de sayısal olarak karşılaştırılmaları içinde yine NetCAD v5.2 yazılımı tercih edilmiştir.

eCognition Developer 9.1 yazılımı, Definiens firması tarafından geliştirilmiş olup günümüzde Trimble firmasına aittir. Sınıflandırma yöntemlerindeki eksiklik ve sınırlamaları minimuma indirerek, nesne tabanlı sınıflandırma yapan diğer yazılımlara göre daha fazla tercih edilmektedir (Baatz ve ark., 2004). Farklı konumsal ve spektral özelliklere sahip algılayıcılara ait görüntü verilerinin birleştirilerek kullanılmasını sağlaması ile de kullanıcılara avantaj sağlamaktadır. ArcGIS 9.3.1, ESRI firması tarafından geliştirilen hem raster hem de vektör veri ile çalışabilen bir yazılımdır. Arayüzü sayesinde kullanıcıya sorgulama ve analiz imkânı sunmasıyla sadece UA çalışmalarında değil, birçok meslek dalındaki çalışmalarda da kullanılan bir yazılım hâline gelmiştir. NetCAD v5.2 yazılımı, NETCAD Yazılım A.Ş tarafından geliştirilen ve kullanıcılara hassas koordinatlı veriyle çalışma imkânı sunan bir yazılımdır. Özellikle haritacılık biliminde kullanılan NetCAD v5.2 yazılımı, projeksiyon farklılıkları ve koordinat dönüşümü ile ilgili sorunları gidermesi sayesinde uzaktan algılama alanında da sıklıkla tercih edilmektedir. Bu çalışmada da uydu görüntüsü ve meşcere haritasının projeksiyon farklılıklarını gidererek ve arayüzünde bulundurduğu dönüşüm parametreleri ile aynı koordinat sistemine getirmeyi sağlayarak, analizler sorunsuz bir şekilde gerçekleştirilebilmiştir.

Aşağıdaki bölümde, uygulamalara geçilmeden önce, nesne tabanlı sınıflandırma yönteminde segmentasyon ve sınıflandırma doğruluğuna ilişkin detaylı bilgi verilmektedir.

2.1. Nesne Tabanlı Sınıflandırma Yöntemi

Nesne tabanlı sınıflandırma yönteminde görüntüdeki tekil pikseller yerine, bu piksellerden oluşturulan anlamlı nesnelere kullanılmaktadır. Sınıfları oluşturan nesnelere şekil, bütünlük, komşuluk ve özellikle ölçek boyutunda, gerçek dünya nesnelere yansıtacak şekilde segmentasyonlarının gerçekleştirilmeleri, sınıflandırma doğruluğu için en önemli etkidir (Shackelford ve Davis 2003; Carleer ve Wolff 2006; Blaschke 2010).

Görüntü üzerinde nesnelere her biri için ölçek parametresi oldukça önemlidir. Büyük bir alan içerisindeki küçük boyutlu nesnelere, büyük ölçek faktörü olarak doğru bir şekilde yansıtılamamaktadır. Bu durumda küçük objeler, kendilerinden farklı sınıflardaki nesnelere birleşerek yanlış sınıflandırma sonuçlarına neden olmaktadır. Sadece piksellerin spektral özelliklerinden başka, konumsal olarak da bilgilerin sınıflandırmaya dâhil edilmeleri doğruluğu oldukça arttıran bir faktördür. Bu anlamda bu konumsal bilginin de segmentasyon aracılığıyla doğru tanımlanması oldukça önemli bir işlem adımıdır (Mathiev ve ark., 2007).

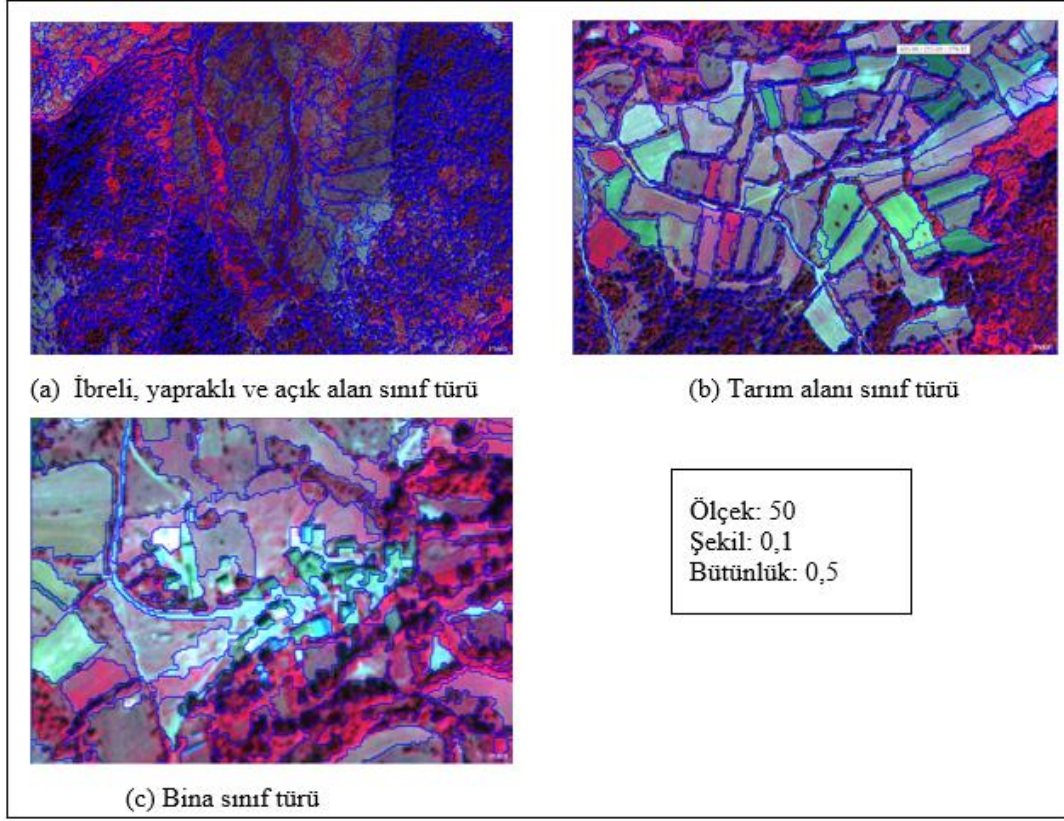
2.1.1. Segmentasyon

Segmentasyon, nesne tabanlı sınıflandırma yönteminin ilk ve en önemli adımıdır. Görüntü segmentasyonunda kullanılan yazılımlar sayesinde nesnelere otomatik olarak çıkartılabilmektedir. Burada önemli olan segmentasyon parametrelerinin görüntü nesnelere uygun değerler verilerek oluşturulmasıdır (Yan ve ark., 2006). eCognition yazılımı kullanıcılara segmentasyon için yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) olmak üzere iki farklı yaklaşım sunmaktadır (Trimble, 2012). Yukarıdan aşağıya prensibine dayalı algoritmalar objelerin büyük parçalardan daha küçük parçalara bölünmesi esas alır. eCognition yazılımı bu yaklaşım için 4 farklı segmentasyon algoritması sunmaktadır. Bu algoritmalar, Chessboard, Quadtree-Based, Contrast Filter ve Contrast Split'tir. Bir diğer algoritma aşağıdan yukarıya, küçük objelerin birleşerek homojen ve daha büyük objelerin oluşması mantığına dayanmaktadır. Bu yaklaşım da kullanıcılar üç farklı algoritma sunmaktadır. Bunlar, Multi-Resolution, Multi-Threshold ve Spectral Difference Segmentasyon algoritmalarıdır. İçlerinde uygulamalarda en sık kullanılan algoritma Multi-Resolution yani Çoklu Çözünürlük algoritmasıdır (Baatz, 2000). Burada amaç spektral (renk) ve şekilsel heterojenite (yumuşaklık ve yoğunluk) kriterler doğrultusunda, anlamlı ve gerçeğe yakın nesnelere oluşturulmaktadır. Alan birleştirme özelliği ile de küçük piksellerin büyük piksel grupları içinde birleşmesini sağlar (Baatz, 2000; Benz ve ark., 2004). Segmentasyon algoritması ile görüntü üzerinden nesnenin homojen ve doğru çıkarımını yapmak için ölçek, şekil ve bütünlük kriterlerinin amaca uygun tanımlanması gerekmektedir. Bu aşamada seçilen segmentasyon parametreleri sınıflandırma doğruluğu için oldukça önemli bir adımdır.

Sınıflandırma için en önemli parametre ölçektir. Ölçek parametresi direkt görüntü nesnesinin boyutunu etkilemektedir. Parametre değeri ne kadar büyük seçilirse görüntü nesnelere arasında ki detay ayrımı o kadar azalacaktır. Birçok nesne birbirinden ayrılmayacak, bu durum da sınıflandırmayı olumsuz etkileyecektir (Maktav ve Sunar, 1991; Benz ve ark., 2004). Şekil parametresi, segmentasyon sonrası oluşacak nesnelere renk ve şekil kriterleri arasındaki ilişkiyi ifade etmektedir. Parametre 0 ile 1 arasında bir değer almaktadır. Aralarında artan ve azalan oranda ters bir ilişki vardır yani şekil kriteri 0.4 iken renk kriteri 0.6 değerini alacaktır. Bütünlük parametresi ise nesnelere daha bütün ve yumuşak olmalarını sağlar. Bu parametre de 0 ile 1 arasında değer alır (eCognition 2011).

Bu çalışmada çoklu çözünürlük (multi resolution) segmentasyon yöntemi kullanılmıştır. Ölçek, şekil ve bütünlük parametrelerinin seçimi için farklı değerler ile denemeler yapılmış ama "Bina ve Açık Alan" sınıflarına ait alanların doğru yansıtılması için ölçek parametresi oldukça küçük seçilmiştir. Denemeler sonrası segmentasyon sonuçlarına bakılmış ve çalışmadaki sınıfları en doğru şekilde yansıtacak değerlerin ölçek parametresi için 50, şekil parametresi için 0.1 ve bütünlük

parametresi için de 0.5 olduğuna karar verilmiştir. Şekil 4'te bu parametre değerleri uygulanarak yapılmış segmentasyon sonucu gösterilmektedir.



Şekil 4. Sınıflara ait segmentasyon sonucu.

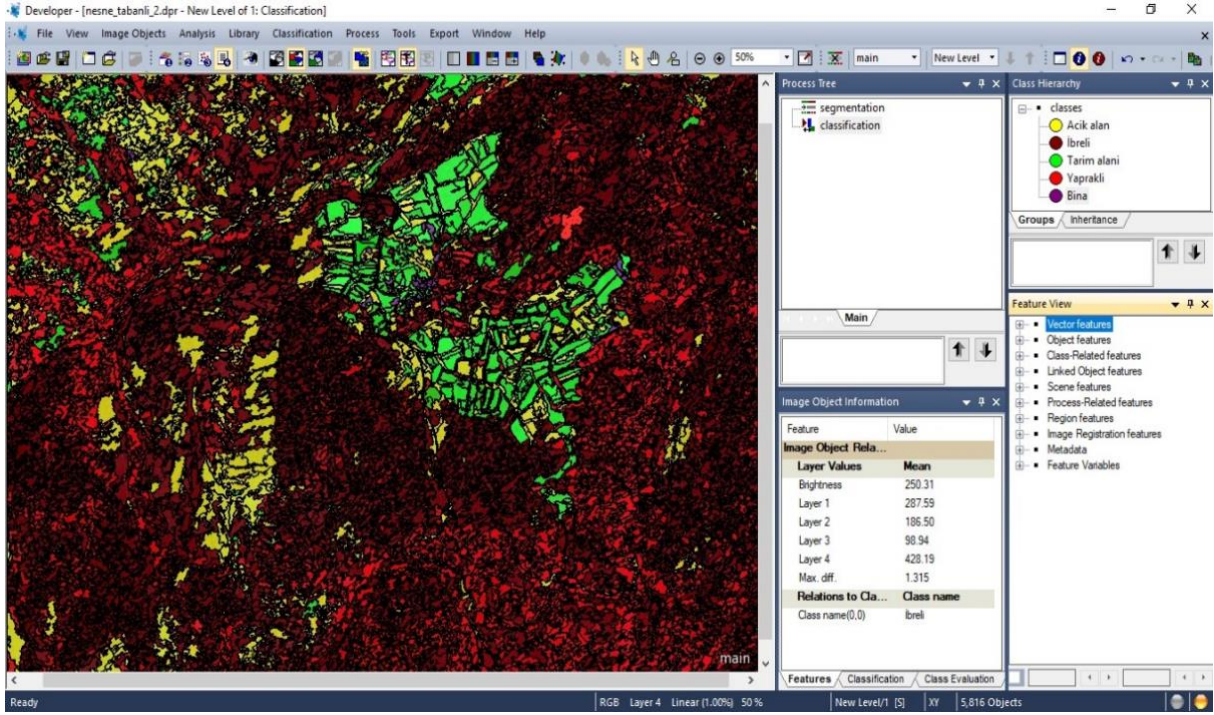
2.1.2. Sınıflandırma Aşaması

Segmentasyon işleminden sonra sınıflandırma için bir yöntem seçilmektedir. Segmentasyon, görüntü üzerinden anlamlı nesnelere oluşmasını sağlar. Kullanıcı artık piksel bazında değil, nesne bazında düşünerek hareket edecektir. Sınıflandırmanın amacı oluşan anlamlı nesnelere, olması gereken sınıflara seçerek atamaktır. Bu işlem sadece spektral değerlere göre değil şekil, doku, içerik ve bunlarla birlikte semantik bilgileri de göz önünde bulundurularak yapılmaktadır.

eCognition yazılımı ile iki farklı şekilde sınıflandırma yapmak mümkündür. İlki en yakın komşuluk (nearest neighbour) sınıflandırma yöntemi ile oluşturulan sınıflara ait segmentasyon sonrası oluşan nesnelere görüntü üzerinden homojen bir dağılımla seçilerek, yazılıma tanıtılması ile yapılmaktadır (Jensen, 1996). İkinci sınıflandırma yöntemi ise, kullanıcının sınıflara ait özellikler ve bunlara tanımlanan eşik değerler ile karar seti dosyaları oluşturmasıyla yapılmasıdır. Segmentasyon için kullanılan parametrelerin değerleri, alansal ve konumsal nitelikler ya da hangi bantın, hangi aralıklarla kullanılacağı gibi özellikler karar seti için belirlenmektedir. Diğer sınıflandırma yönteminden farkı, kullanıcı segmentasyon sonrası oluşan nesnelere üzerinden bir seçim yapmaz, onun

yerine yazılıma tanıtılan kurallar bazında nesnelere otomatik olarak sınıflara aktarılır. Burada yeterli görülmediği durumlarda karar setlerine eklemeler ya da eşik değerlerde değişiklikler yapılabilmektedir.

Bu çalışmada eCognition yazılımının kullanıcılara sunduğu en yakın komşuluk sınıflandırma yöntemi seçilerek sınıflandırma yapılmıştır. Şekil 5'te eCognition yazılımında tanımlanan sınıflar ve kurallar gösterilmektedir.



Şekil 5. eCognition yazılımı ile sınıflar ve kuralların tanımlanması.


2.1.3. Sınıflandırma Doğruluğu

Sınıflandırma doğruluğu, sınıflandırmanın son işlem adımındır. Bu işlem, arazi çalışması, hava fotoğrafları ya da yüksek çözünürlüklü uydu görüntüleri, büyük ölçekli haritalar gibi farklı verilerle desteklenebilmektedir. Hata matrisi oluşturmak, doğruluk için en yaygın kullanılan yöntemdir. Hata matrislerinin amacı sınıflara atanan nesnelere, gerçek dünya nesnelere yüzdelik olarak birbirlerine yakınlıklarını referans verilerle sağlamaktır. Hata matrisi ile kullanıcı doğruluğu (KD), üretici doğruluğu (ÜD) ve genel doğruluk (GD) yaygın olarak hesaplanan değerlerdir (Yan, 2003). Kullanıcı Doğruluğu (KD)-(User Accuracy-UA), sınıflandırılan pikselin gerçekte o sınıfa ne kadar ait olduğunu gösterir. Üretici Doğruluğu (ÜD)- (Producer Accuracy-PA), piksel veya nesnenin gerçek değerinde sınıflandırma yüzdeliğini gösteren değerdir. Genel Doğruluk (GD)- (Overall Accuracy-OA) ise her bir sınıf için doğru şekilde sınıflandırılmış piksel ya da nesne sayısının, toplam referans piksel sayısına bölünmesiyle hesaplanmaktadır. Kullanıcı ve üretici doğruluğunun hesaplanması genel bir

doğruluk değerlendirmesi yapılmasını sağlar. Kappa Değeri (k) ise hata matrisinin satır ve sütun elemanlarının toplamı ve ana köşegen üzerindeki elemanlar kullanılarak hesaplanır. 0 ile 1 arasında bir değer alır. Değerin 1'e yakınlığı sınıflandırma başarısı ile doğru orantılıdır (Lillesand ve ark., 2015). Değerlendirme sonrası istenilen durum, kappa değerinin genel doğruluktan küçük olmasıdır. Doğruluk kriteri model değerlendirmelerinde sıklıkla kullanılan bir değer olmakla birlikte "Kesinlik, Hassasiyet ve F1 Skoru"da tercih edilen kriterler arasındadır. Kesinlik, oluşturulan modelin ne kadar doğru olduğunu; Hassasiyet, modelde oluşturulan örneklemelerin ne kadar doğru seçildiğini ya da modelin doğru örneklem bulma yeteneğini; F1 Skoru ise kesinlik ve hassasiyeti birleştiren bir modelin harmonik ortalaması, bir fonksiyonunu göstermektedir (Sunnetci ve ark.,2023). Bu çalışmada GD ve Kappa Değeri kriterli kullanılarak doğruluk analizi gerçekleştirilmiştir.

3. Bulgular ve Tartışma


GeoEye-1 uydu görüntüsü üzerinden "İbrelî, Yapraklı, Tarım alanı, Bina ve Açık alan" olmak üzere beş adet sınıf belirlenerek nesne tabanlı sınıflandırma ile analizler gerçekleştirilmiştir. eCognition yazılımı ile yapılan sınıflandırmada en yakın komşuluk (nearest neighbour) yöntemi seçilerek sonuçlar elde edilmiştir. Şekil 6'da sınıflandırma sonrası elde edilen GeoEye-1 uydu görüntüsü gösterilmektedir.




Şekil 6. Sınıflandırılmış GeoEye-1 uydu görüntüsü

Her ne kadar segmentasyon parametrelerinin seçiminde özellikle nesne büyüklükleri yeterli hassasiyette seçilmiş ve sınıflandırma işleminde homojen bir dağılımla nesnelere sınıflara atanmış olsa da, bazı sınıflara ait hatalı sınıflandırma sonuçları görülmektedir. Aşağıdaki Şekil 7, Şekil 8, Şekil 9,


Şekil 10 ve Şekil 11’de sınıflandırılmış görüntü ile sınıflandırma öncesi yapay renkli GeoEye-1 uydu görüntüsü görsel olarak karşılaştırılmıştır.




Şekil 7. Nesne tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-1.



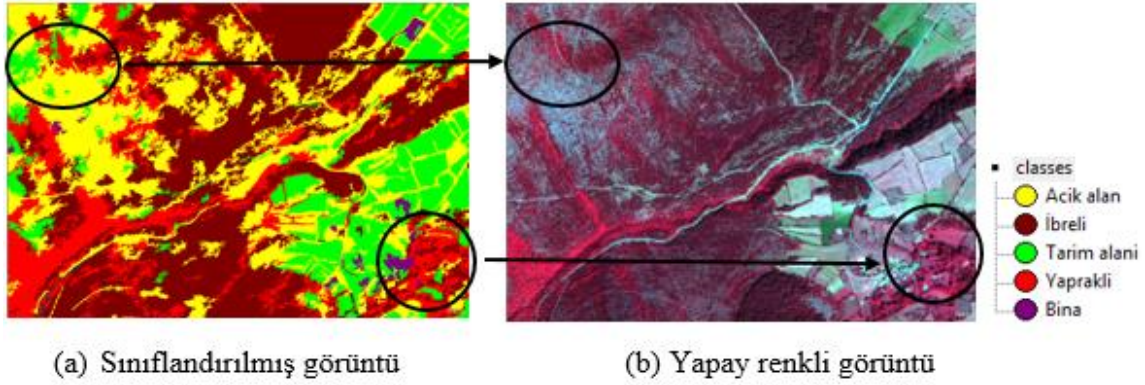
Şekil 8. Nesne tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-2.



Şekil 9. Nesne tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-3.



Şekil 10. Nesne tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-4.



Şekil 11. Nesne tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-5.

Şekillere bakıldığında özellikle “Bina, Açık alan ve Tarım alanı” sınıflarında spektral yansıma değerlerinin benzerliğinden kaynaklı yanlış sınıflara atandıkları görülmektedir. “Açık alan” ya da “Bina”ların, “Tarım Alanı” olarak sınıflandırılması çalışmanın genelinde bir sorun olarak karşımıza çıkmıştır. Hatta bazı sınıfların tamamen özelliklerini kaybederek o bölgede başka bir sınıfa atandıkları gözlemlenmiştir. “İbrelî ve Yapraklı” sınıf türlerinin ise görsel olarak gerçeğe yakın bir şekilde sınıflandırıldıkları görülmektedir. Bu da hem yakın kızılötesi bant ile çalışmanın hem de sınıflandırma parametre ve algoritmalarının ormanlık alanlar için başarılı sonuçlar verdiğini göstermektedir.

Bundan sonraki işlem adımı, sınıflandırma doğruluğunun analizinin yapılmasıdır. Sınıflandırma doğruluğunun analizi için eCognition yazılımındaki “Statistic Type Error Matrix based on Samples” yöntemi seçilerek kullanılmıştır. Bu yöntem ile segmentasyon sonrası seçilen örnek alanlar gibi, doğruluk analizinde de sınıflar için homojen dağılımla örnek alanlar seçilmektedir. Tablo 2’de de doğruluk analizi sonucunda elde edilen yüzdelik değerler gösterilmektedir.

Tablo 2. Nesne tabanlı sınıflandırmaları için doğruluk analizi sonuçları.


Sınıflar	En Yakın Komşuluk		
	ÜD (%)	KD (%)	Kappa
İbrelili	%93.58	%97.22	0.897
Yapraklı	%97.17	%88.80	0.963
Tarım alanı	%78.57	%91.67	0.748
Bina	%75	%81.81	0.744
Açık alan	%89.89	%81.63	0.873
Genel Doğruluk		%90.59	
Kappa		0.872	

Tablo 2’deki sayısal yüzdeler değerlere bakıldığında genel olarak, spektral yansıma değerlerinin benzerliğinden kaynaklı yanlış sınıflandırılan alanlar olmasına rağmen yine de yüksek doğruluklu sonuçlar elde edildiği görülmektedir. Bu da bir çalışma için başarılı bir sınıflandırma yapıldığının sonucudur.

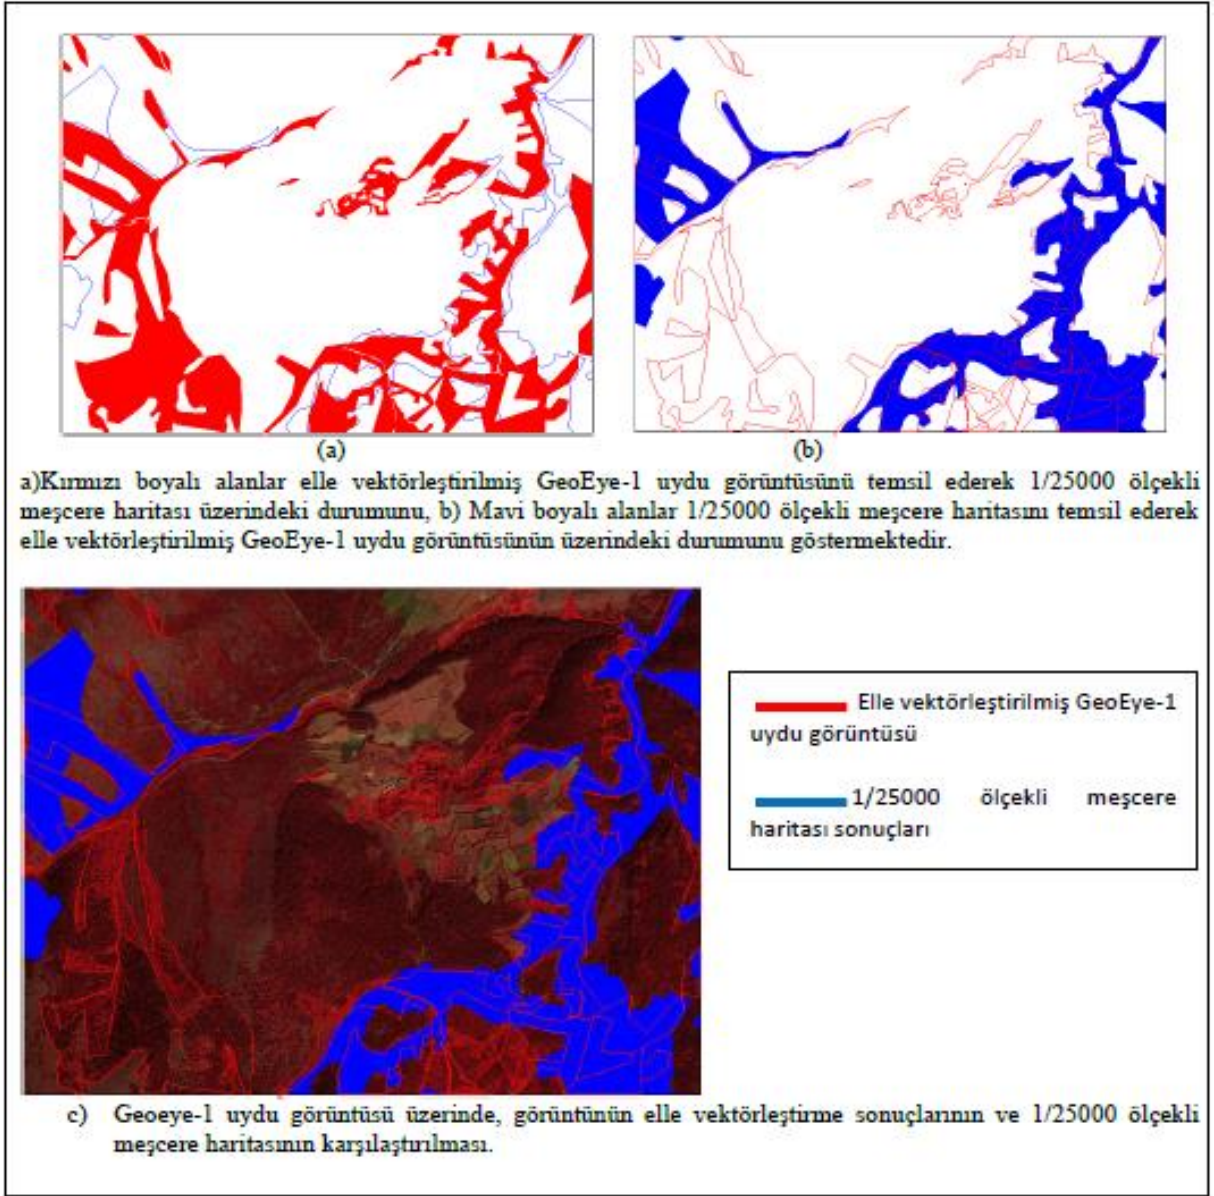
Nesne tabanlı sınıflandırma yöntemi ile başarıyla sınıflandırılan GeoEye-1 uydu görüntüsü, eCognition yazılımının “export” menüsü ile vektörleştirilerek “*.shp” uzantılı bir dosya olarak kaydedilmiştir. Kaydedilen GIS tabanlı dosya, ArcGIS 9.3.1 yazılımında sınıflara ayrılarak, NetCAD v5.2 yazılımında kullanılmak üzere “*.NCZ” uzantılı dosya olarak kaydedilmiştir. CAD sistemi üzerinden çalışılmasının nedeni, pratik ve dinamik bir şekilde vektör veriler ile işlemlerin yapılabildiği içindir. Nesne tabanlı sınıflandırma sonuçlarının vektörleştirilmesinden sonra, GeoEye-1 uydu görüntüsü de hassas bir şekilde elle sayısallaştırılmıştır. Bu işlemin devamında 1/25000 ölçekli meşcere haritası da raster veri üzerinden elle sayısallaştırılarak, vektör veri elde edilmiştir. Çalışmanın devamında elle vektörleştirilmiş GeoEye-1 görüntüsü baz alınarak nesne tabanlı sınıflandırma verisinin doğruluğu ve meşcere haritasının sınıflar üzerindeki detay ve ayırım başarısı analiz edilmek üzere, vektör veriler karşılaştırılmıştır.

3.1. Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü ile 1/25000 Ölçekli Meşcere Haritasının Karşılaştırılması


Aşağıdaki Şekil 12, Şekil 13, Şekil 14, Şekil 15 ve Şekil 16’da, elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden tüm sınıflara ait vektör veriler görsel olarak karşılaştırılmıştır.




Şekil 12. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “İbrelî” sınıfına ait vektör verilerin karşılaştırılması.



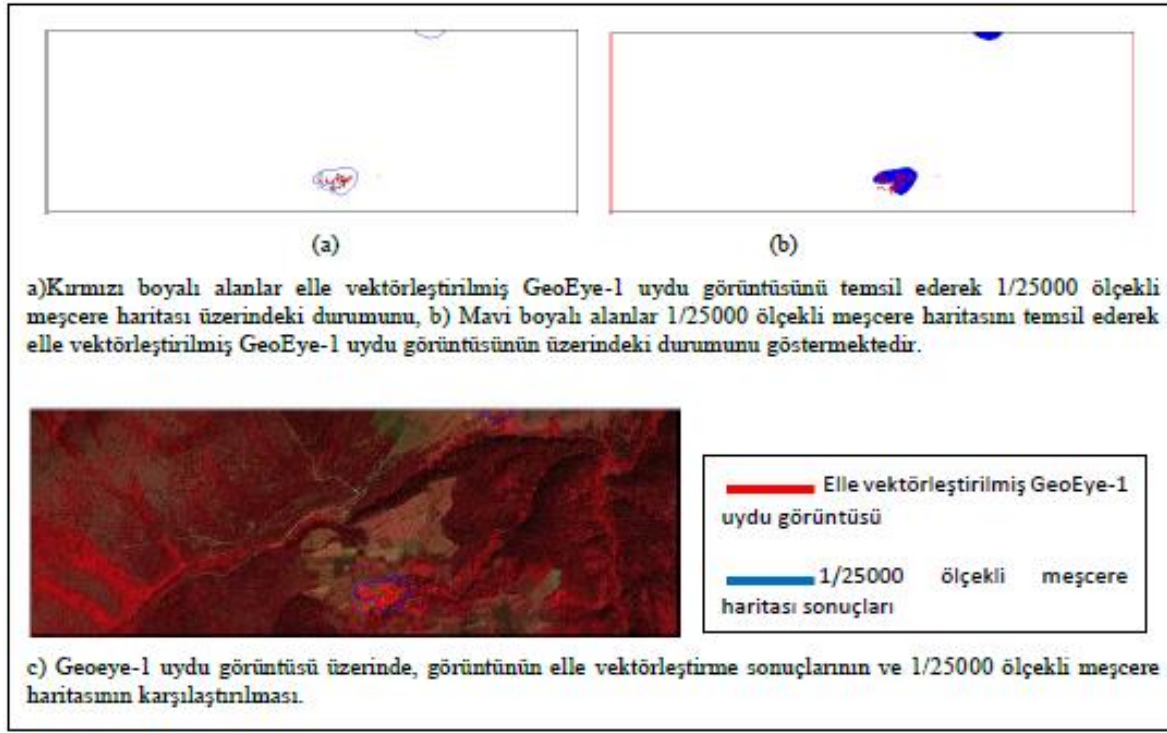
Şekil 13. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Yapraklı” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 14. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Tarım alanı” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 15. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Açık alan” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 16. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Bina” sınıfına ait vektör verilerin karşılaştırılması.

Analizlerde kullanılan meşcere haritası, çalışma alanı olan Kastamonu Orman Bölge Müdürlüğünden temin edilmiş olup tescilli bir harita olduğu için geometrik doğruluğu, temin edildiği şekilde, sorgulanmadan kullanılmıştır. Yukarıdaki şekillere bakıldığında sınıflar arası kayıklıkların mevcut olduğu görülmektedir. Bunun nedeni meşcere haritası ile uydu görüntüsü arasındaki konumsal doğruluğun farklı olmasından kaynaklanmaktadır. Meşcere haritasının üretiminde kullanılan kontrol noktalarının sayısı ve hassasiyetleri, büyük ölçekli olmasından kaynaklı belirli bir metrekaresinin altındaki alanların haritada gösterilmemesi, üretildiği yıldan bu zamana kadar arazi örtüsü üzerinde meydana gelen değişim ve yıpranma payının sayısallaştırma üzerindeki olumsuz etkileri düşünüldüğünde aynı doğrulukla sonuç vermemelerine neden olarak gösterilebilir. Tablo 3’te NetCAD v5.2 yazılımı ile her iki vektör veriye ve sınıflara ait hesaplanan alanlar gösterilmektedir.

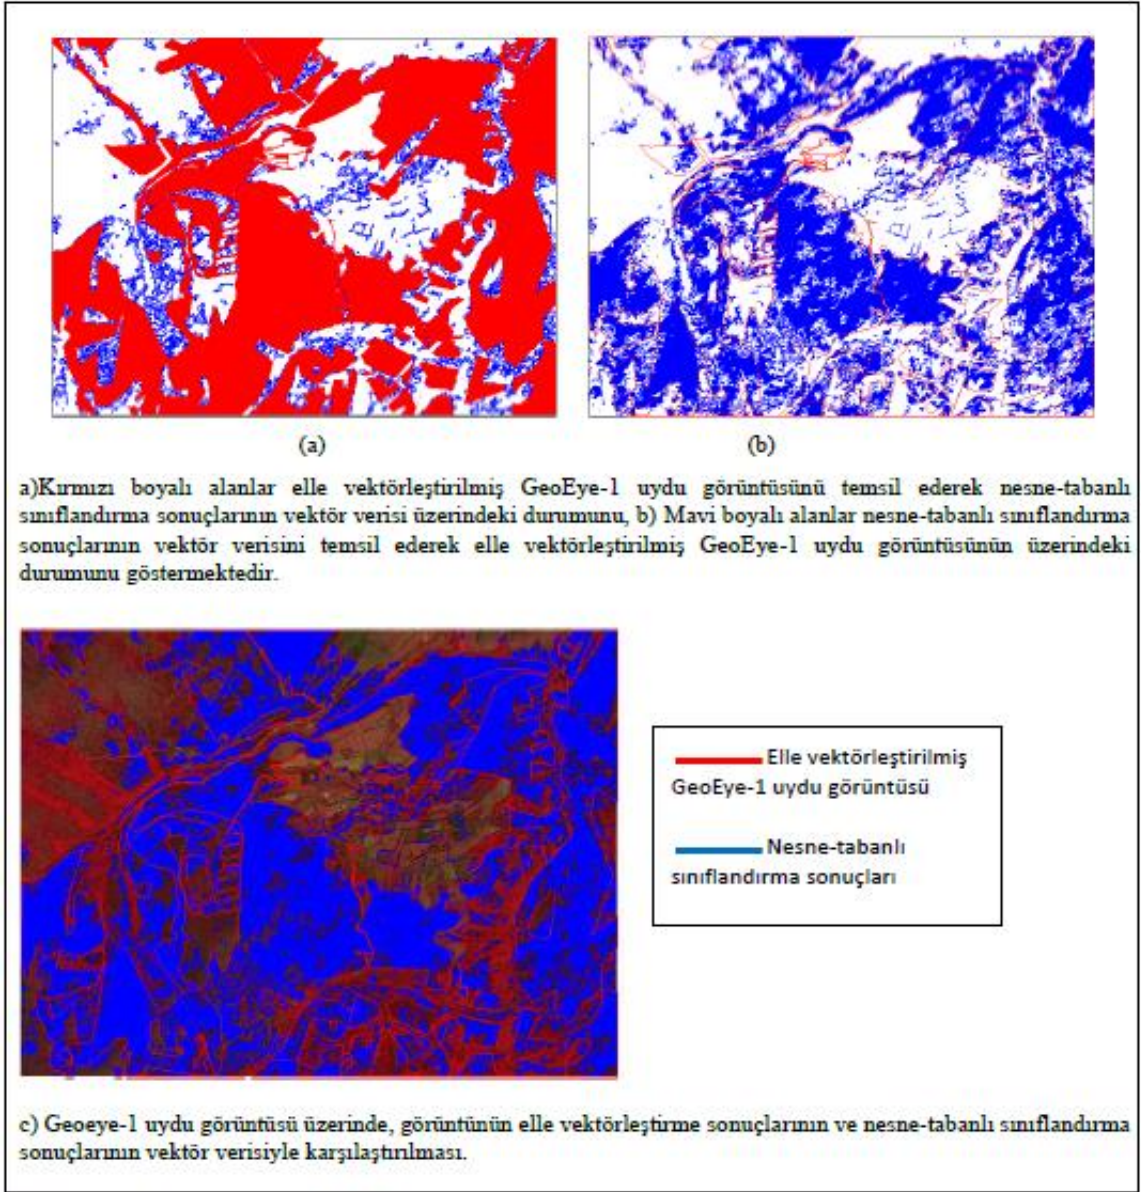
Tablo 3. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve meşcere haritasına ait vektörleştirme sonuçlarının alan cinsinden karşılaştırılması.

Sınıf	Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü (m ² -%)	1/25000 Ölçekli Meşcere Haritası (m ² -%)
İbrelî	5416952.35 (% 100)	6529591.94 (% 120)
Yapraklı	2225442.03 (% 100)	1791739.26 (% 81)
Tarım alanı	805756.80 (% 100)	878141.14 (% 109)
Açık alan	1711143.21 (% 100)	298091.70 (% 17)

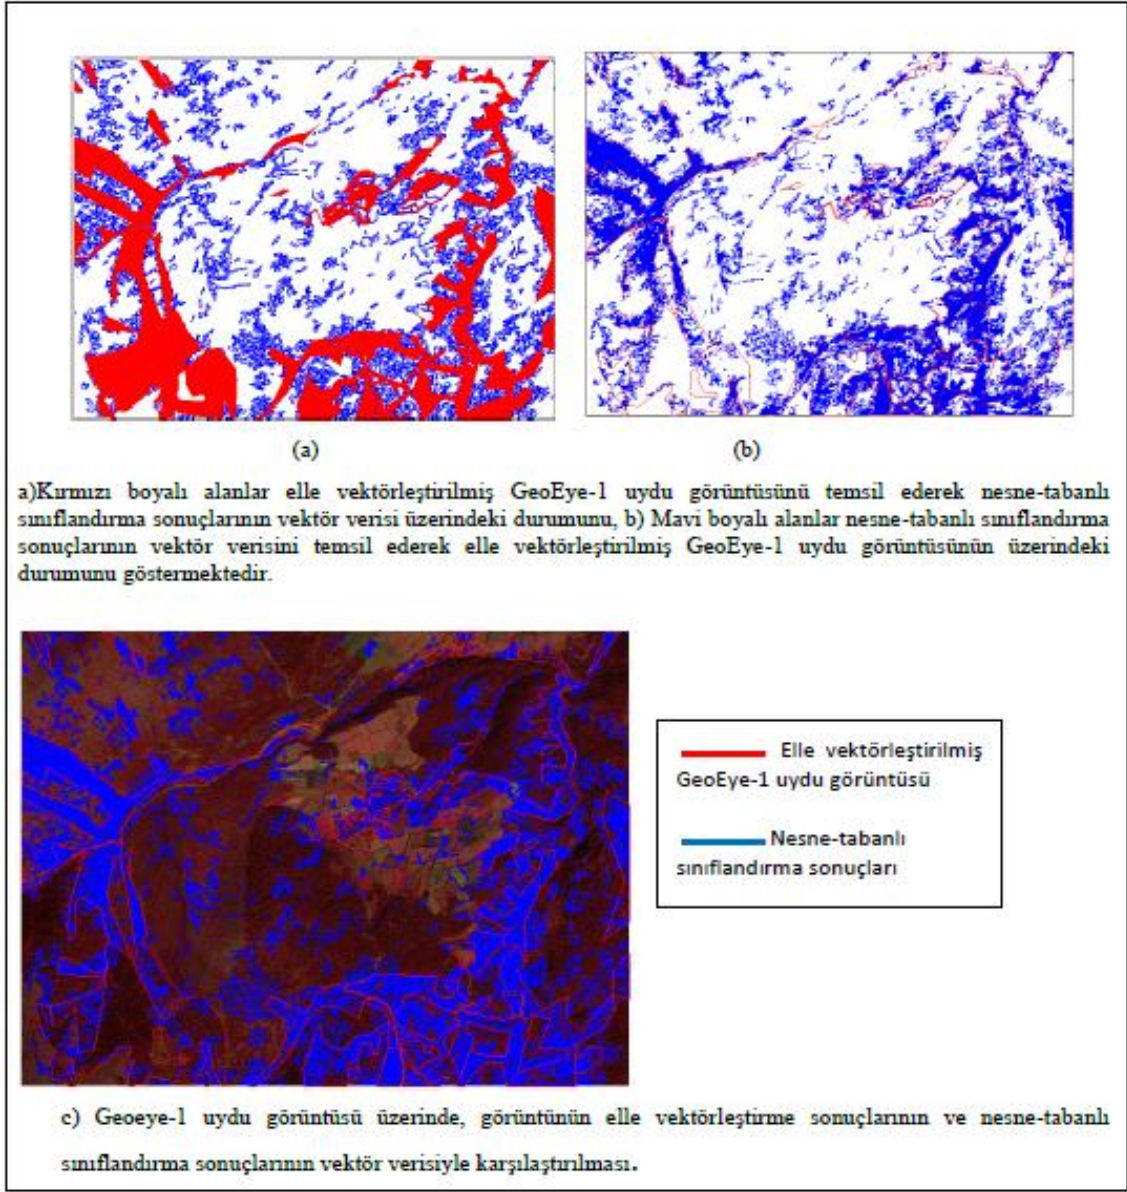
Ormancılık alanında hemen her uygulamada kullanılan meşcere haritalarında 3000 m²'nin altında kalan alanlar gösterilmemektedir. Daha çok büyük ormanlık alanlar ve ağaç türleri için kullanılan bu büyük ölçekli harita, yerleşim alanları için uygun bir altlık kesinlikle değildir. O yüzden bu çalışmada “Bina” sınıfı için bir değerlendirme yapılamamıştır. Meşcere haritasında bina ve yollar birleştirilerek yerleşim alanı olarak gösterilmektedir. Bu durumda sayısal ve görsel analizlerde sınıflara ait yanlış sonuçlar elde edilmesine neden olmaktadır. “İbrelili ve Yapraklı” sınıf türleri karşılaştırıldığında ise meşcere haritasında “İbrelili” sınıfına ait daha fazla alan olduğu görülmektedir. Bu durumun tam tersi olarak da “Yapraklı” sınıfında bir azalma mevcuttur. Meşcere haritasının arazi örtüsü ayrımını hassas yapmaması ya da geometrik doğruluk ve zamansal değişimden kaynaklı da sınıflara ait farklılıklar analiz sonuçlarına yansımıştır. “Açık alan” sınıfa ait alanların görüntü genelinde oldukça fazla bir alana sahip olmasına rağmen, aralarda ve küçük alanlara sahip olduğu için meşcere haritasında da neredeyse gösterilmediği; nesne tabanlı sınıflandırma sonuçlarında ise ayırt edilebilir detaylarla birlikte yüksek doğrulukla sınıflandırıldığı da elde edilen bir başka sonuçtur.

3.2. Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü ile Nesne Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması


Uygulamanın bu bölümünde elle vektörleştirilmiş GeoEye-1 uydu görüntüsü, nesne tabanlı sınıflandırma sonuçları sonrası elde edilen vektör veri ile hem görsel hem de sayısal olarak karşılaştırılmıştır. Aşağıdaki Şekil 17, Şekil 18, Şekil 19, Şekil 20 Ve Şekil 21’de elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden vektör verilerin karşılaştırılması gösterilmiştir.




Şekil 17. Elle vektörlendirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden “İbrelî” sınıfına ait vektör verilerin karşılaştırılması.



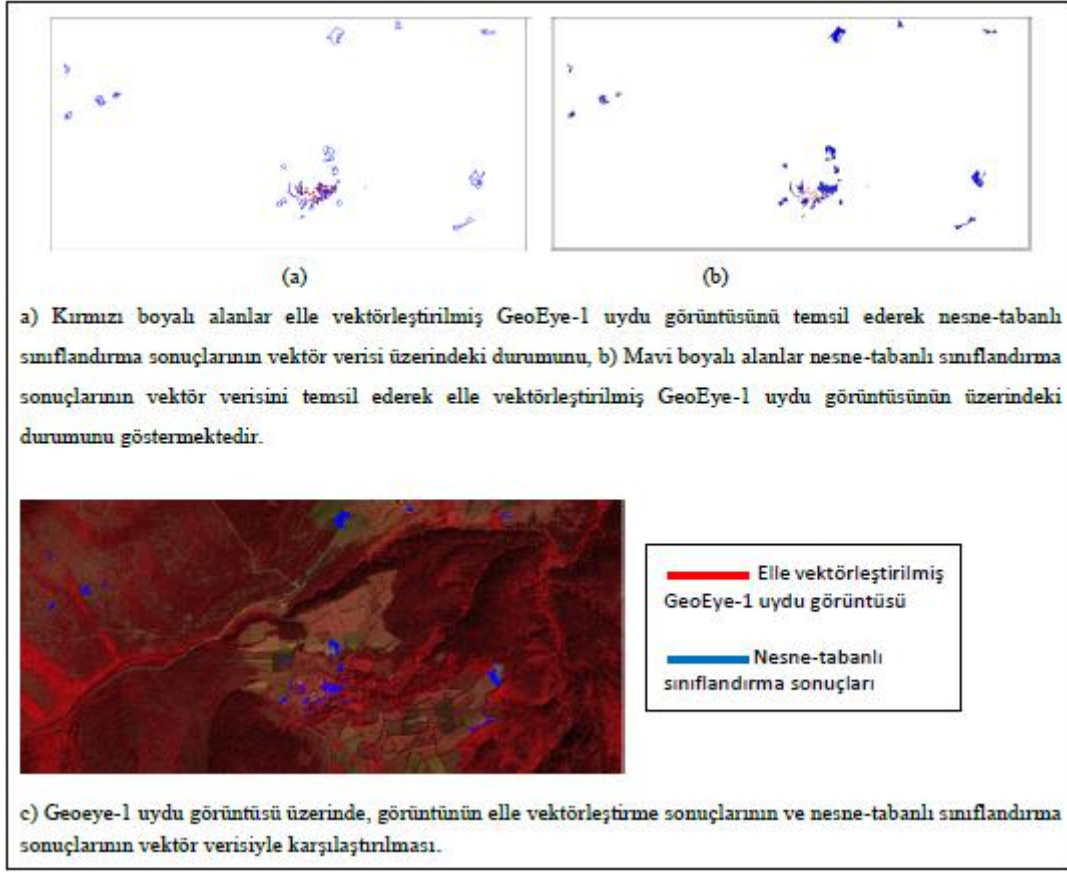
Şekil 18. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden “Yapraklı” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 19. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden “Tarım alanı” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 20. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden “Açık alan” sınıfına ait vektör verilerin karşılaştırılması.



Şekil 21. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırma sonuçları üzerinden “Bina” sınıfına ait vektör verilerin karşılaştırılması.

Tablo 4’te NetCAD v5.2 yazılımı ile her iki vektör veriye ve sınıflara ait hesaplanan alanlar gösterilmektedir.

Tablo 4. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne tabanlı sınıflandırmaya ait vektörleştirme sonuçlarının alan cinsinden karşılaştırılması.

Sınıf	Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü (m ² -%)	Nesne Tabanlı Sınıflandırma (m ² -%)
İbrelî	5416952.35 (%100)	4487888.00 (%83)
Yapraklı	2225442.03 (%100)	2682672.00 (%121)
Tarım alanı	805756.80 (%100)	702576.00 (%87)
Açık alan	1711143.21 (%100)	1630268.00 (%95)
Bina	5787.63	29728.00

Sonuçlar incelendiğinde “İbrelî ve Yapraklı” sınıf türlerinin, elle vektörleştirilmiş uydu görüntüsüne göre alansal olarak farklılık gösterdiği sonucu elde edilmiştir. Nesne tabanlı sınıflandırmada ölçek parametresinin oldukça küçük seçilmesi, sınıflandırılan görüntünün yüksek doğrulukla ve orman örtü tiplerinin gerçeğe yakın üretilmesini sağlamıştır. Elle vektörleştirilen veri de ise, piksel bazında detaylı ayırım yapılamamakla birlikte, bazı alanlarda hangi orman örtü tipi

yoğunlukta ise nesnelere o sınıfa atanmıştır. Ağaç tiplerinin birbirlerine karıştıkları alanlar, piksel bazında, insan gözüyle çok detaylı ayırt edilemeyebilmektedir. Alansal farklılığın nedenlerinden biri bu durum olmakla birlikte, spektral yansıma değerlerinin bazı alanlarda gölgenin yarattığı olumsuz durumlar ya da benzer değerlere sahip olmalarından kaynaklı da olabilmektedir. Nesne tabanlı sınıflandırma sonuçlarında görülen bir başka durum ise, “Bina ve Tarım alan”larının birbirlerinin sınıflarına atanmaları olmuştur. Elle vektörleştirme ve sınıflandırma sonuçları için “Bina” sınıfı irdelendiğinde aralarında oldukça fazla bir fark olduğu gözlemlenmektedir. Buna neden olarak bu sınıfa ait nesne tabanlı sınıflandırma sonuçlarının sadece “Bina”ları değil etrafında ve görüntünün tamamında ki benzer spektral yansıma değerlerine sahip “Tarım alanı” ya da “Açık alan” sınıflarını da dâhil etmesi gösterilebilir. Aynı görüntü verisi ile çalışılmasına rağmen, sonuçlar arasında farklılıkların görülmesi, çalışma prensiplerinin analizler üzerinde ki etkisini göstermektedir.

Literatüre bakıldığında nesne tabanlı sınıflandırma için farklı uydu görüntüleri kullanılarak birçok çalışma yapıldığı görülmektedir. Ateşoğlu (2007), SPOT4 ve LANDSAT görüntü verileri ile ormanlık alanlardaki sınıf türlerini kapsayan bir çalışma yürütmüştür. SPOT 4’ün geometrik çözünürlüğü daha yüksek olmasına rağmen, sınıflandırma sonuçlarında LANDSAT uydu görüntüsünün daha başarılı sonuçlar verdiğini elde etmiştir. Buna neden olarak da SPOT 4’ün geometrik çözünürlüğü yüksek olsa dahi radyometrik çözünürlüğünün istenilen ayırım düzeyini karşılayamaması ve ormanlık alanlarda yapılan çalışmalarda spektral varyansın, yüksek çözünürlüklü görüntülerde sınıflar arası karışıklık yaratarak sınıflandırma başarısını düşürdüğü sonucunu elde etmiştir. Yurtseven (2012), ormanlık alanda arazi örtü tiplerinin sınıflandırılması üzerine, WorldView-2 uydusuyla yaptığı çalışmada, konumsal çözünürlüğün yüksek olmasından dolayı ibrelili ağaçların tepe taçlarının sınıflandırmasında yüksek doğruluklu sonuç etmiştir. Ancak çalışma alanı içerisindeki Karaçam ve Sahil Çamı orman örtü tipleri için spektral çözünürlük yeterli olmadığı için istenilen sınıflandırma başarısı elde edilememiştir. Çalışma alanının tamamında ki bütün orman örtü tiplerinin ayırımı için kullanılan uydu görüntüsünün yeterli olmadığı, spektral çözünürlüğün daha yüksek olduğu bir görüntü ile çalışmanın daha iyi olacağı sonucunu elde etmiştir. Avcı ve Sunar (2018), İstanbul’un 3. Havalimanının bulunduğu bölgeyi, çok geniş bir ormanlık alana yapıldığı ve arazi örtüsünde meydana gelen değişimi belirlemek için, çalışma alanı olarak seçmişlerdir. Çalışmada 2015 ve 2017 yılı tarihli, elektromanyetik spektrumun görünür-kızılötesi (VNIR) bölgesinde algılanmış 4 spektral banda ve 10m mekânsal çözünürlüğe sahip Sentinel 2A uydu verisi kullanılmışlardır. Görüntü verisi üzerinden arazi üzerinde belirlenen sınıf türlerinin ayırımı ve değişimlerinin analizi için nesne tabanlı sınıfları yöntemi ile farklı segmentasyon parametreleri ile de uygulamalar yaparak en uygun seçimi belirlemişlerdir. Sınıflandırmış görüntüyü, sınıflandırma öncesi orijinal görüntü ile karşılaştırarak görsel yorumlama ile çalışmalarını tamamlamışlardır. Yiğit ve Uysal (2019), İnsansız Hava Aracı (İHA) yardımıyla oluşturdukları görüntü verisi üzerinden

mevcut yolların tespiti için eCognition yazılımı kullanarak nesne tabanlı sınıflandırma ile detay çıkarımı yapmışlardır. Sınıflandırma sonrası sonuç ürünleri jeodezik yöntemle yapılan arazi çalışması ile elde edilen vektör ürünle karşılaştırmışlar ve %82'lik bir doğruluk elde etmişlerdir. Nesne tabanlı sınıflandırma sonuçlarında yolların spektral yansımalarının özellikle kaldırım taşı ve bina çatıları ile benzerlik göstermesi sonuçları olumsuz etkilemiş olsa bile, elde edilen doğruluk oranının yüksek olması hem yöntemin hem de yazılımın gerçek dünyaya yakın sonuçlar verdiğini göstermiştir. Ersoy ve ark. (2019) kıyı habitatlarının belirlenmesi için Sentinel-2A uydu görüntüsü ile eCognition yazılımı kullanarak nesne tabanlı sınıflandırma yapmışlardır. Sonuç doğruluğunu artırmak için NASA Earthdata websitesinden ücretsiz olarak temin edilen 30m yersel çözünürlüklü ASTER Global DEM sayısal yükseklik modeli verisi İl Özel İdare'den temin ettikleri toprak haritadan faydalanmışlardır. 17 habitat sınıfı belirlenen çalışmada ek veriler sayesinde de istenilen doğrulukla detay çıkarımı sağlanmıştır. Arda (2020)'de Muğla ili, Ula ilçesi kapsamında orman örtü tiplerini de içeren çalışma alanının 1990 yılına ait Landsat 5 TM uydu görüntüsü uydusu ile 2019 yılına ait Landsat 8 (OLI) uydu görüntüsü ile nesne tabanlı sınıflandırma yapmış ve test alana ait mevcut haritalar, hava fotoğrafları ile sonuçları desteklemiştir. eCognition yazılımı kullanılarak yapılan bu çalışmada, sınıflandırma sonuçları karşılaştırıldığında Landsat 8 (OLI) uydu görüntüsünün daha doğru sonuçlar verdiği sonucu elde edilmiştir. Torunlar ve ark. (2021) Sentinel-2A uydu görüntüsü kullanarak çalışma alanına ait altı farklı tarım arazi örtüsü belirlemişler ve sonuç başarısını arttırmak için de eğitim ve test verilerinin dışında NDVI ve DDVI gibi farklı yardımcı indisler de kullanmışlardır. Nesne tabanlı sınıflandırma sonucunda %82 doğruluk başarısı elde etmişler ve yöntemin tarım arazileri ile ilgili yapılan farklı çalışma disiplinlerince de kullanılabilir olduğunu göstermişlerdir. Arıkan ve Yıldız (2023), nüfus artışı dolayısıyla plansız yapılaşmanın artması sonrası, bu alanların tespiti için nesne tabanlı sınıflandırma ile bina detay çıkarımı yapmışlardır. Göktürk-1 uydu görüntüsü kullanarak gerçekleştirdikleri çalışmalarında, sınıflandırmanın en önemli aşaması olan segmentasyon için hazır veri seti modeli olan U-Net modelini kullanmışlar ve daha az manuel müdahalenin olması sonucunda da gerçeğe yakın, olumlu sonuçlar elde etmişlerdir.

5.Sonuç ve Öneriler

Bu çalışmada Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliğine ait 24 320 ha büyüklüğündeki yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden 12X12 km'lik alan, orman örtü tipleri ve yerleşim alanlarına ait sınıflar seçilerek belirlenmiştir. Görüntünün büyük bir kısmını "İbrelili ve Yapraklı" sınıf türlerini kapsarken, "Açık alan, Tarım alanı ve Bina" sınıf türleri de görüntü üzerinde mevcuttur. Beş farklı sınıfın bulunduğu bir alanın seçilmesinin nedeni, orman örtü tiplerinin başarısı kadar, veriler üzerinde diğer sınıf türlerinin de başarısını gözlemlemek

olmuştur. Sınıflandırma, görüntüler üzerinde birçok amaçla kullanılmaktadır. Zamansal değişimler en sık tercih edilen uygulamalar olsa da, nesnelere hangi veri sayesinde başarıyla ayrımlarının yapıldığı da çalışmalar için oldukça önemli bir sonuçtur. Ormancılık faaliyetlerinde neredeyse her uygulamada kullanılan meşcere haritalarının yerini, yüksek çözünürlüklü uydu görüntülerinin farklı yazılımlar kullanılarak daha başarılı sonuçların elde edilmesinin alıp alamayacağını araştırılması, bu alanda yapılacak çalışmalar için altlık oluşturabilecektir.

Uygulamalar için iki farklı veri ve üç farklı yazılım kullanılmıştır. Yüksek çözünürlüklü GeoEye-1 uydu görüntüsü, hem nesne tabanlı sınıflandırma hem de elle vektörleştirilerek, vektör verilerin karşılaştırılması için kullanılırken; 1/25000 ölçekli meşcere haritası da yine elle vektörleştirilerek sayısallaştırılmıştır. Nesne tabanlı sınıflandırma için eCognition, sınıflandırılmış görüntüden elde edilen vektör verinin, CAD ortamında kullanılmasını sağlamak için ArcGIS ve uydu görüntüsü ve meşcere haritasının sayısallaştırılması için de NetCAD yazılımı kullanılmıştır.

Çalışmaya ilk olarak nesne tabanlı sınıflandırma uygulaması ile başlanmıştır. Sınıflandırma sonucuna göre genel doğruluk %90.59 kappa değeri ise 0.872 olmuştur. Kappa değerinin 1'e yakın ve genel doğruluktan küçük olması, uzaktan algılama çalışmalarında istenilen, başarılı bir durumdur. Orman örtü tiplerinden "İbrelili ve Yapraklı" sınıf türlerinin birbirlerinden homojen ve yüksek doğrulukla ayrılması, hem görsel hem de sayısal sonuçlara yansımıştır. "Tarım alanı, Açık alan ve Bina" sınıf türlerinin %70 doğruluğun üzerinde sonuçlar vermesi ise, birbirlerine benzer spektral yansıma değerlerine sahip olmalarına rağmen olumlu bir durum sonuç olmuştur. Görüntü üzerinde "Bina ve Açık alan" için ölçek parametresinin küçük seçilmesi, diğer sınıflarında daha detaylı segmentlere ayrılarak, doğru sınıflandırmalarını sağlamıştır. Ancak gölgelik alanların sınıf türlerinin yansıma değerlerini etkilediği durumlarda sınıflandırma doğruluğunda azalma olduğu da görülmüştür. GeoEye-1 uydu görüntüsünün kullanılmasının en önemli sebebi yakın kızılötesi banta sahip olmasıdır. Yeşil bitkiler bünyelerinde buldukları klorofil nedeniyle, bu bantta daha az soğurularak oldukça yüksek yansıma değerine sahip olmaktadır. Bu durum avantaj gibi görünse de, GeoEye-1 uydu görüntüsünün yüksek çözünürlüğe sahip olması spektral varyansın artmasını sağlarken, spektral olarak arazi örtü tiplerinin birbirlerinden ayrımını da zorlaştırmaktadır. Bu nedenle ormanlık alanların sınıflandırılmasında yüksek çözünürlüklü uydu görüntüsü kullanmak yerine orta çözünürlüklü bir uydu görüntüsünün kullanılmasının, sınıflandırma sonuçlarını daha olumlu etkileyeceği sonucu elde edilmiştir.

Nesne tabanlı sınıflandırma sonuçlarının elde edilmesi sonrasında, raster veri olan aynı uydu görüntüsü NetCAD ortamında elle vektörleştirilerek sayısallaştırılmıştır. Elde edilen bu vektör veri, analizler için baz alınan veri olarak kullanılmıştır. GeoEye-1 uydu görüntüsünün elle vektörleştirilmesi, hem zaman hem de kullanıcı hatasının olabilmesi açısından dezavantajlı bir durum yaratsa da, görüntüdeki gölge ya da topoğrafyadan kaynaklı sorunlara müdahale edilebilmesi

açısından avantajlı bir durumdur. 1/25000 ölçekli meşcere haritası sayısallaştırılırken, uydu görüntüsü ile alım ve yapım tarihlerinin farklılığından kaynaklı zamansal değişim, analizlere yansımıştır. Bununla birlikte meşcere haritasının büyük ölçekli olması ve yüksek bir doğrulukla üretilmemesi de, yüksek çözünürlüklü uydu görüntüsüyle karşılaştırıldığında kayıklıklara neden olmuştur. Ayrıca meşcere haritalarının büyük ormanlık alanlar için üretilmeleri, ormanlık alanlar içerisinde kalan bina gibi donatılar ve alanlar arası yol ve açıklıkları da bünyesinde barındırmamaktadır. Bu durumda bizim çalışmamızda ki özellikle “Bina ve Açık alan” sınıf türleri olumsuz etkilenmiştir. Bu iki veri için sayısal ve görsel analizlere bakıldığında, uydu görüntülerinin ormancılık çalışmalarında, orman örtü tiplerindeki yüksek başarısı doğrultusunda, meşcere haritalarının yerine kullanılabileceğini görülmüştür.

Elle vektörleştirilen uydu görüntüsünün, aynı görüntü üzerinden nesne tabanlı sınıflandırma sonuçları ile karşılaştırılmasında, zamandan kaynaklanabilecek olumsuz bir durum olmamakla birlikte, hatalı sınıf farklılıkları yine de gözlemlenmiştir. Özellikle “Bina” sınıf türünde bu fark oldukça net bir şekilde görülmektedir. Bunun nedeni ise nesne tabanlı sınıflandırmada her ne kadar ölçek boyutu bu sınıf için uygun olmuş olsa da, spektral yansıma değerlerinin “Tarım alanı ve Açık alan” sınıflarıyla benzerlik gösterdiği bölgelerde yanlış sınıflandırılmış olmasıdır. Tam tersi bir durum olarak da elle vektörleştirilen görüntü üzerinde, insan gözünün en küçük piksel boyutunu ayırt edemeyerek sınıf bazında detaylı bir ayırım yapamaması, buna karşın nesne tabanlı sınıflandırmanın da piksellerin spektral yansımalarını oldukça hassas ele alarak sınıflandırma yapabilmesi, veriler arası alansal farklılıklara neden olmuştur. Özellikle orman örtü tiplerinin sınıflandırma başarıları yaklaşık benzer olduğu için, nesne tabanlı sınıflandırmanın pratik, dinamik ve hızlı bir çalışma prensibine sahip olması, sınıflandırma çalışmaları için avantajlı ve olumlu bir durum oluşturacağı sonucu göstermiştir. Gelecekteki uygulamalarda, arazide jeodezik yöntemle ölçümler yapılarak, sınıflandırma sonucunun gerçek arazi yüzeyini yakın tarihli olarak nasıl yansıttığının; farklı çözünürlüklü uydu görüntülerinin ormanlık alanlar için özellikle spektral yansıma değerlerini nasıl etkilediğinin çeşitli yazılım ve algoritmalar kullanılarak gösterilmesinin hem bu çalışmanın sonuçları hem de literatür için faydalı olacağı düşünülmektedir.

Detay çıkarımı genelinde yapılan sınıflandırma uygulamalarından segmentasyon, referans veri ve eğitim seti seçme ya da doğruluk analizleri gibi işlem adımları günümüzde birçok farklı çalışma disiplinlerince de kullanılmaktadır. Uydu görüntüleri üzerinden arazi örtüsü kullanımı, zamansal değişim, afet yönetimi, fay hatlarını tespit etmek ya da meydana gelen değişimleri analiz etmek kadar; sağlık alanında, Covid-19 Pandemi sürecinde de özellikle göğüs röntgenlerinde meydana gelen değişimleri tespit etmek adına yapılan çalışmalar mevcuttur (Sunnetci ve Alkan, 2023). Sürdürülebilir enerjiye geçiş sürecinde yenilenebilir enerji santrallerinin kurulum sahaları, santralin enerji kapasitesinin ölçülmesi, yüzey pürüzlülüğünün hesaplanması için de sınıflandırma tekniklerinin

kullanıldığı çalışmalar da yine literatürde bulunmaktadır (Naccaroğlu, 2016; Aydın-Kandemir ve Sarptaş, 2022). Kimya, fizik, inşaat, elektrik elektronik gibi birden çok farklı çalışma alanında da ulusal ve uluslararası çeşitli projelerde kullanımının, yüksek doğrulukla elde edilen sonuçlar doğrultusunda sıklıkla kullanılabilceği, uygulama ve araştırma sonrası önerilebilecek nitelikte bir yaklaşımdır.

Teşekkür

Bu çalışma sorumlu yazarın “Yüksek Çözünürlüklü Görüntü Verileri Kullanarak Ormanlık Alanlarda Sınıflandırma Uygulamaları” başlıklı yüksek lisans tezinden üretilmiş olup, çalışmaya katkı sunan çok değerli tez danışmanı Dr. Öğr. Üyesi Aycan Murat MARANGOZ’a teşekkür ederiz. Ayrıca çalışmada kullanılan, radyometrik ve geometrik düzeltilmeleri yapılmış GeoEye-1 uydu görüntüsünün temini için Prof. Dr. Burak ARICAK’a, meşcere haritası için de Kastamonu Orman Bölge Müdürlüğüne teşekkürlerimizi sunarız.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Arda, G. (2020). Landsat Uydu Görüntüleri Kullanılarak Nesne Tabanlı Sınıflandırma Yöntemi ile Alan Kullanım/Arazi Örtüsü Değişiminin Değerlendirilmesi: Muğla-Ula Örneği. *ArtGRID-Journal of Architecture Engineering and Fine Arts*, 2(1), 49-61.
- Arıkan, D., ve Yıldız, F. Göktürk-1 Uydu Görüntülerinden U-Net Modeli Kullanılarak Binaların Segmentasyonu. *Türkiye Uzaktan Algılama Dergisi*, 5(1), 50-58.
- Ateşoğlu, A., Tunay, M., Topan, H., ve Oruç, M. (2007). Uydu Görüntüleri Bilgi İçeriğinin Ormancılık Çalışmaları Açısından Değerlendirilmesi. *Orman Kaynaklarının İşlevleri Kapsamında Darboğazları, Çözüm Önerileri ve Öncelikler*, 17, 19.
- Avcı, Z. D. U., ve Sunar, F. (2018). Nesne Tabanlı Arazi Örtüsü/Arazi Kullanımı Değişim Analizi: İstanbul 3. Havalimanı.

- Aydın-Kandemir, F., ve Sarptaş, H. (2022). Toprak Üstü Biyokütle Potansiyelinin CBS ve Uzaktan Algılama ile Belirlenmesi–Yeni Bir Yaklaşım. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 24(70), 165-178.
- Baatz, M. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angewandte geographische informationsverarbeitung*, 12-23.
- Baatz, M., Benz, U., Dehghani, S., Heynen, M., Höltje, A., Hofmann, P., and Willhauck, G. (2004). eCognition professional user guide 4. *Definiens Imaging, Munich*.
- Benz, U. C., Hofmann, P., Willhauck, G., Lingenfelder, I., and 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.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 65(1), 2-16.
- Blaschke, T., and Strobl, J. (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Zeitschrift für Geoinformationssysteme*, 12-17.
- Carleer, A. P., and Wolff, E. (2006). Urban land cover multi-level region-based classification of VHR data by selecting relevant features. *International Journal of Remote Sensing*, 27(6), 1035-1051.
- Colkesen, I., and Kavzoglu, T. (2017). The use of logistic model tree (LMT) for pixel-and object-based classifications using high-resolution WorldView-2 imagery. *Geocarto International*, 32(1), 71-86.
- eCognition (2011) Trimble Documentation. *eCognition Developer 8.7 User Guide*, München, Germany, 258pp.
- Ersoy, E., Yılmaz, K. T., Atak, B. K., ve 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.
- Holland, D. A., Boyd, D. S., and Marshall, P. (2006). Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors. *ISPRS Journal of Photogrammetry and Remote Sensing*, 60(3), 212-223.
- Jensen, J. R. (1996). *Introductory digital image processing: a remote sensing perspective* (No. Ed. 2). Prentice-Hall Inc.
- Lillesand, T., Kiefer, R. W., and Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Maktav, D., ve Sunar, F. (1991). Uzaktan algılama: Kantitatif yaklaşım. *Swain, Philip H., Davis, Shirley M. 'den çeviri*.
- Mathieu, R., Aryal, J., and Chong, A. K. (2007). Object-based classification of Ikonos imagery for mapping large-scale vegetation communities in urban areas. *Sensors*, 7(11), 2860-2880.
- Neccaroğlu, V. (2016). *Rüzgar enerjisi çalışmalarında yüzey pürüzlülüğünün sayısal görüntü işleme yöntemleri ile analizi ve uygulaması* (Master's thesis, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü).
- Shaban, M. A., and Dikshit, O. (2001). Improvement of classification in urban areas by the use of textural features: the case study of Lucknow city, Uttar Pradesh. *International Journal of remote sensing*, 22(4), 565-593.
- Shackelford, A. K., and Davis, C. H. (2003). A combined fuzzy pixel-based and object-based approach for classification of high-resolution multispectral data over urban areas. *IEEE Transactions on GeoScience and Remote sensing*, 41(10), 2354-2363.
- Sunnetci, K. M., and Alkan, A. (2022). Biphasic majority voting-based comparative COVID-19 diagnosis using chest X-Ray images. *Expert Systems with Applications*, 119430.
- Sunnetci, K. M., Kaba, E., Celiker, F. B., and Alkan, A. (2023). Deep Network-Based Comprehensive Parotid Gland Tumor Detection. *Academic Radiology*.
- Torunlar, H., Tuğaç, M. G., ve Duyan, K. (2021). Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya-Karapınar Örneği. *Türkiye Uzaktan Algılama Dergisi*, 3(2), 36-46.
- Trimble (2012). *eCognition Developer User Guide*, Trimble Germany GmbH, München, 261 pp.
- URL-1: http://www.nik.com.tr/content_sistem_uydu.asp?id=12 Erişim tarihi: 14.03.2023
- Yan, G. (2003, March). Pixel based and object oriented image analysis for coal fire research. Enschede, The Netherlands: ITC.
- Yan, G., Mas, J. F., Maathuis, B. H. P., Xiangmin, Z., and Van Dijk, P. M. (2006). Comparison of pixel-based and object-oriented image classification approaches—a case study in a coal fire area, Wuda, Inner Mongolia, China. *International journal of remote sensing*, 27(18), 4039-4055.

- Yiğit, A. Y., ve Uysal, M. (2019). Nesne Tabanlı Sınıflandırma Yaklaşımı Kullanılarak Yolların Tespiti. *Türkiye Fotogrametri Dergisi*, 1(1), 17-24.
- Yurtseven, H. (2014). Yüksek Çözünürlüklü Uydu Verileri ile Obje Tabanlı Görüntü Analizleri. *Fen Bilimleri Enstitüsü. İstanbul, Türkiye, İstanbul Üniversitesi*, 147.