

BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜ VERİLERİ KULLANARAK ORMANLIK
ALANLARDA SINIFLANDIRMA UYGULAMALARI



GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ
DUYGU BIYIKLI

ARALIK 2017

BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜ VERİLERİ KULLANARAK ORMANLIK
ALANLARDA SINIFLANDIRMA UYGULAMALARI



GEOMATİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Duygu BIYIKLI

DANIŞMAN: Yrd. Doç. Dr. Aycan Murat MARANGOZ

ARALIK 2017


KABUL:

Duygu BIYIKLI tarafından hazırlanan “Yüksek Çözünürlüklü Görüntü Verileri Kullanarak Ormanlık Alanlarda Sınıflandırma Uygulamaları” Başlıklı bu çalışma jürimiz tarafından değerlendirilerek Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir. 19/12/2017

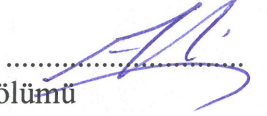
Danışman: Yrd. Doç. Dr. Aycan Murat MARANGOZ
Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü



Üye: Doç. Dr. Umut Güneş SEFERCİK
Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Geomatik Mühendisliği Bölümü



Üye: Doç. Dr. Ayhan ATEŞOĞLU
Bartın Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü



ONAY:

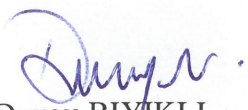
Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

..../..../2017



Doç. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”


Duygu BIYIKLI

ÖZET

Yüksek Lisans Tezi

YÜKSEK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜ VERİLERİ KULLANARAK ORMANLIK ALANLARDA SINIFLANDIRMA UYGULAMALARI

Duygu BIYIKLI

Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Geomatik Mühendisliği Anabilim Dalı

Tez Danışmanı: Yrd. Doç. Dr. Aycan Murat MARANGOZ

Kasım 2017, 111 Sayfa

Uzaktan algılama teknolojilerinin gelişmesi ve beraberinde getirdiği Coğrafi Bilgi Sistemleri (CBS), ormancılık çalışmalarında da aktif olarak kullanılmayı başlanmıştır. Bu çalışmalarda yüksek konumsal çözünürlüğe sahip (<1 metre) multispektral görüntüler kullanılarak orman örtü tiplerinin, piksel-tabanlı ve nesne-tabanlı sınıflandırma yöntemlerinin kullanılması ile elde edilen sonuçlar değerlendirilmiştir.

Bu tez çalışmasında kullanılan GeoEye-1 uydu görüntüsü üzerinden çıkartılabilecek detaylara ilişkin sınıflandırma yöntemleri karşılaştırılmış ve bu şekilde harita üretim sürecinde altlık olarak kullanılabilir, doğru bilgiyi kullanıcıya sunan yöntemler belirlenmiştir. Bu amaçla Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliğine ait sınırlar içerisinde çalışma alanı belirlenerek, 2011 yılına ait yüksek çözünürlüklü GeoEye-1 uydu görüntüsü kullanılmış olup arazi örtü tipleri ve diğer sınıf türlerinin sınıflandırma başarıları incelenmiştir. Piksel-tabanlı sınıflandırma Erdas Imagine 2015, nesne-tabanlı sınıflandırma eCognition Developer

ÖZET (devam ediyor)

9.1 yazılımı kullanılarak yapılmış olup, sonuç ürünler vektörleştirilerek CBS ortamında karşılaştırmalar yapılmak üzere hazır hale getirilmiştir. Elde edilen ürünler, elle vektörleştirilmiş GeoEye-1 uydu görüntüsü vektör veri ve araziden her sınıf için alınmış toplamda 150 adet nokta ile görsel ve sayısal olarak analiz edilmiştir. Değerlendirmeler sonucunda, ormancılık çalışmalarında altlık olarak kullanılan meşcere haritalarının düşük geometrik doğruluğa sahip olması ve zamansal değişimden kaynaklı güncel bilgiyi içermemesinin yeni çalışmalar için dezavantaj olacağı belirlenmiş olup, sınıflandırma yöntemlerinin verdikleri sonuçlara göre harita üretimi ya da harita üretim sürecine altlık olmak üzere kullanılabileceklerinin yorumu yapılmıştır.

Anahtar Kelimeler: Piksel-Tabanlı Sınıflandırma, Nesne-Tabanlı Sınıflandırma, GeoEye-1 Uydu Görüntüsü, eCognition, Erdas Imagine.

Bilim Kodu: 616.02.04

ABSTRACT

M. Sc. Thesis

CLASSIFICATION APPLICATIONS IN FOREST AREAS USING HIGH RESOLUTION IMAGES

Duygu BIYIKLI

Bülent Ecevit University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

Thesis Advisor: Assist. Prof. Dr. Aycan Murat MARANGOZ

November 2017, 111 pages

Remote sensing technologies and the accompanying geographical information systems (GIS) introduced by them have started to be used actively in forestry studies. The results obtained by using pixel-based and object-based classification methods of forest cover types through using multispectral images with high spatial resolution (<1 meter) are evaluated in these studies.

The classification methods of detail that can be extracted from the GeoEye-1 satellite image used in this thesis study are compared, and in this way, methods that provide the user with the correct information that can be used as a base in the map production process have been determined. For this purpose, high resolution GeoEye-1 satellite image of 2011 was used and the classification of land cover types and other class species was investigated by determining the study area within the boundaries of the Kastamonu Regional Directorate of Forestry and the Central Business Administration.

ABSTRACT (continued)

Upon making pixel-based classification with Erdas Imagine 2015, and object-based classification with eCognition Developer 9.1 software, the resulting products were vectorized and made ready for comparison in the GIS environment. The obtained products were visually and numerically analyzed with a manually digitized GeoEye-1 satellite image, which was taken as reference, and a total of 150 points for each class in the field. As a result of the evaluations, it has been determined that the landscape maps used as a base for forestry studies have low geometrical accuracy and that the lack of up-to-date information due to temporal variation is a disadvantage for new studies and that the classification methods can be used as a map production or as a base for the map production process.

Keywords: Pixel-Based Classification, Object-Based Classification, GeoEye-1 Satellite Image, eCognition, Erdas Imagine.

Science Code: 616.02.04

TEŐEKKÜR

Yüksek lisans eğitimim ve çalışmalarım süresince bilgi, birikim ve tecrübeleriyle desteğini esirgemeyen, beni her daim yönlendiren, her türlü sorunumda gerekli imkanı sağlayan çok değerli hocam ve tez danışmanım Yrd. Doç. Dr. Aycan Murat MARANGOZ'a teşekkürü bir borç bilirim. Çalışmam süresince değerli fikirleriyle çalışmalarımı yönlendiren Arş. Gör. Alihsan ŐEKERTEKİN'e de teşekkür ederim. Ayrıca deneyim ve bilgilerinden yararlandığım, tez çalışmasında kullanılmak üzere uydu görüntüsünü temin eden Kastamonu Üniversitesi Orman Fakültesi hocalarımdan, çok değerli hocam Doç. Dr. Burak ARICAK'a da teşekkürlerimi sunarım.

Son olarak, yalnız tez çalışmam süresince değil tüm yaşamım boyunca bana her zaman güvenerek arkamda olan ve her türlü desteği sağlayan çok değerli annem ve babam Nurhan ve Metin BIYIKLI'ya ve canım kardeşim Tolga BIYIKLI'ya sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ	xvii
SİMGELER VE KISALTMALAR DİZİNİ.....	xix
BÖLÜM 1 GİRİŞ	1
1.1. ÇALIŞMANIN AMACI	4
1.2. ÇALIŞMANIN KAPSAMI	5
BÖLÜM 2 UZAKTAN ALGILAMADA TEMEL KAVRAMLAR.....	7
2.1. ELEKTROMANYETİK ENERJİ VE ELEKTROMANYETİK SPEKTRUM	7
2.2. ATMOSFERİK ETKİLER	8
2.2.1. Görüntünün Geometrik Düzeltilmesi.....	9
2.2.2. Görüntünün Zenginleştirilmesi	9
2.3. NESNELERİN SPEKTRAL ÖZELLİKLERİ	11
2.4. ALGILAYICI TÜRLERİ.....	12
2.4.1. Doğrusal Dizin (Pushbroom) Görüntüleme Sistemleri.....	12
2.5. UZAKTAN ALGILAMADA ÇÖZÜNÜRLÜK KAVRAMI	14
2.5.1. Konumsal Çözünürlük	14
2.5.2. Radyometrik Çözünürlük.....	16
2.5.3. Spektral Çözünürlük	17
2.5.4. Zamansal Çözünürlük	18

İÇİNDEKİLER (devam ediyor)

Sayfa

BÖLÜM 3 UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA TEKNİKLERİ .. 21

3.1. PİKSEL-TABANLI SINIFLANDIRMA YAKLAŞIMI	22
3.1.1. Kontrolsüz (Eğitimsiz) Sınıflandırma Yöntemi	22
3.1.2. Kontrollü (Eğitilmiş) Sınıflandırma Yöntemi	23
3.1.2.1. Maximum Benzerlik Sınıflandırma Yöntemi	23
3.2. NESNE-TABANLI SINIFLANDIRMA YAKLAŞIMI	25
3.2.1. Segmentasyon	27
3.2.1.1. Yukarıdan Aşağıya (Top-Down) Stratejisi	28
3.2.1.2. Aşağıdan Yukarı (Bottom-Up) Stratejisi	29
3.2.2. Segmentasyon Parametreleri	31
3.2.2.1. Ölçek Parametresi	32
3.2.2.2. Şekil Parametresi	35
3.2.2.3. Bütünlük Parametresi	35
3.2.3. Sınıflandırma Aşaması	36
3.2.4. Sınıflandırma Doğruluğu	37

BÖLÜM 4 UYGULAMA

4.1. ÇALIŞMA ALANI	41
4.2. ÇALIŞMADA KULLANILAN VERİ VE YAZILIM	42
4.3. METODOLOJİ	45
4.4. PİKSEL-TABANLI SINIFLANDIRMA	46
4.4.1. Geoeye-1 Uydu Görüntüsünden Piksel-Tabanlı Sınıflandırma	47
4.4.2. Sonuç Ürünlerin Doğruluk Analizi	49
4.5. NESNE-TABANLI SINIFLANDIRMA	55
4.5.1. Segmentasyon Parametrelerinin Seçimi	56
4.5.2. GeoEye-1 Uydu Görüntüsünden En yakın Komşuluk Yöntemiyle Sınıflandırma (Nearest Neighbour)	62
4.5.3. Sonuç Ürünlerin Doğruluk Analizleri	63
4.5.4. Nesne-Tabanlı ve Piksel-Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması	68
4.5.5. Nesne-Tabanlı Sınıflandırma Sonuçlarının Vektör Ürün Haline Çevrilmesi	69

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
4.6. CBS ORTAMINDA DEĞERLENDİRME.....	71
4.6.1. Görüntü Üzerinden Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü ile 1/25000 Ölçekli Meşcere Haritası Sonuçlarının Karşılaştırılması.....	72
4.6.2. Görüntü Üzerinden Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü ile Nesne-Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması	78
4.6.3. CBS Ortamındaki Karşılaştırılmalı Analiz Sonuçlarının İrdelenmesi.....	85
4.7. SONUÇLARIN ARAZİ VERİLERİ İLE DEĞERLENDİRİLMESİ.....	87
BÖLÜM 5 SONUÇ VE ÖNERİLER.....	101
KAYNAKLAR.....	107
ÖZGEÇMİŞ	111



ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Elektromanyetik dalgalar.	7
Şekil 2.2 Elektromanyetik spektrum.	8
Şekil 2.3 Pan-sharp işlemi.	10
Şekil 2.4 Farklı yer örtü tipleri için genelleştirilmiş spektral yansıtım grafiği.	11
Şekil 2.5 Doğrusal dizi görüntüleme sistemi	13
Şekil 2.6 Yer örnekleme aralığı.	14
Şekil 2.7 Uzaktan algılama uyduları için anlık görüş alanının açısız ve uzunluk olarak ifadesi.	15
Şekil 2.8 Konumsal çözünürlük kavramı. (a) 1 metre, (b) 10 metre, (c) 30 metre YÖA değerine sahip görüntüler.	16
Şekil 2.9 Radyometrik çözünürlük kavramı (a=2 bit, b=8 bit).	17
Şekil 2.10 Spektral çözünürlük kavramı (a) Pankromatik görüntü, (b) Multispektral görüntü.	18
Şekil 2.11 Spot uydularının elektromanyetik spektrumunda algıladıkları bölgeler ve bant özellikleri.	18
Şekil 2.12 Yıllara ait bölgedeki ormanlık alanlardaki zamansız değişimin izlenmesi.	19
Şekil 3.1 Olasılık yoğunluk fonksiyonları.	24
Şekil 3.2 Yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) yaklaşımı.	28
Şekil 3.3 Grid segmentasyonu.	28
Şekil 3.4 Dörtlü ağaç yapısı segmentasyonu.	29
Şekil 3.5 Geoeye-1 uydu görüntüsünden alınmış 3 farklı ölçek parametresi (a- 50 küçük ölçek, b- 100 orta ölçek, c-200 büyük ölçek).	33
Şekil 4.1 Çalışma alanının Türkiye üzerindeki konumu.	41
Şekil 4.2 Çalışma alanının yüksek çözünürlüklü Geoeye-1 uydusuna ait görüntüsü.	42
Şekil 4.3 Kastamonu Merkez Orman İşletme Şefliğine ait meşcere haritası.	43
Şekil 4.4 İş akış şeması.	46
Şekil 4.5 Yapay renkli görüntü üzerinden eğitim alanlarının seçilmesi.	48
Şekil 4.6 Eğitim alanlarının birleştirilerek sınıfların oluşturulması.	48
Şekil 4.7 Maksimum benzerlik parametresinin seçimi.	49

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 4.8 Çalışma alanına ait yapay renkli yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.	49
Şekil 4.9 Çalışma alanına ait yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.	50
Şekil 4.10 Sınıflandırılmış yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.....	50
Şekil 4.11 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-1.	51
Şekil 4.12 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-2.	51
Şekil 4.13 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-3.	52
Şekil 4.14 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-4.	52
Şekil 4.15 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-5.	52
Şekil 4.16 Doğruluk analizi için oluşturulan kontrol noktaları.	54
Şekil 4.17 Yazılımın ve kullanıcının sınıf numaralarının tanımlanması.....	54
Şekil 4.18 Farklı parametreler ile segmentasyon sonucu örneği-1.	58
Şekil 4.19 Farklı parametreler ile segmentasyon sonucu örneği-2.	59
Şekil 4.20 Farklı parametreler ile segmentasyon sonucu örneği-3.	60
Şekil 4.21 Farklı parametreler ile segmentasyon sonucu örneği-4.	61
Şekil 4.22 eCognition yazılımı ile sınıflar ve kuralların tanımlanması.....	63
Şekil 4.23 Sınıflandırılmış GeoEye-1 uydu görüntüsü.	64
Şekil 4.24 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-1.....	64
Şekil 4.25 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-2.....	64
Şekil 4.26 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-3.....	65
Şekil 4.27 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-4.....	65
Şekil 4.28 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-5.....	65
Şekil 4.29 Doğruluk analizi için seçilen “Error Matrix based on Samples” yöntemi ile yeniden örnek alanların seçilmesi.	67
Şekil 4.30 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “İbrelî” sınıfının vektör ürünleri.	69
Şekil 4.31 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Yapraklı” sınıfının vektör ürünleri.	70
Şekil 4.32 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Tarım alanı” sınıfının vektör ürünleri.	70

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 4.33 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Açık alan” sınıfının vektör ürünleri.	71
Şekil 4.34 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Bina” sınıfının vektör ürünleri.	71
Şekil 4.35 Referans vektör veri ve 1/25000 ölçekli meşcere haritası üzerinden “İbrelî” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	72
Şekil 4.36 Referans vektör veri ve 1/25000 ölçekli meşcere haritası üzerinden “Yapraklı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	73
Şekil 4.37 Referans vektör veri ve 1/25000 ölçekli meşcere haritası üzerinden “Tarım Alanı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	74
Şekil 4.38 Referans vektör veri ve 1/25000 ölçekli meşcere haritası üzerinden “Açık Alan” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	75
Şekil 4.39 Referans vektör veri ve 1/25000 ölçekli meşcere haritası üzerinden “Bina” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	76
Şekil 4.40 Referans vektör veri ve nesne-tabanlı sınıflandırma sonuçları üzerinden “İbrelî” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	79
Şekil 4.41 Referans vektör veri ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Yapraklı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	80
Şekil 4.42 Referans vektör veri ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Tarım alanı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	81
Şekil 4.43 Referans vektör veri nesne-tabanlı sınıflandırma sonuçları üzerinden “Açık alan” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	82
Şekil 4.44 Referans vektör veri nesne-tabanlı sınıflandırma sonuçları üzerinden “Bina” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.	83
Şekil 4.45 Araziden alınan noktaların uydu görüntüsü üzerindeki dağılımı.	88
Şekil 4.46 İbrelî sınıf türüne ait arazi noktalarının elle sayısallaştırılmış uydu görüntüsü ile değerlendirilmesi.	90
Şekil 4.47 Yapraklı sınıf türüne ait arazi noktalarının nesne-tabanlı sınıflandırma sonucu ile değerlendirilmesi.	90
Şekil 4.48 Tarım alanı sınıf türüne ait arazi noktalarının 1/25000 ölçekli meşcere haritası ile değerlendirilmesi.	91
Şekil 4.49 Açık alan sınıf türüne ait arazi noktalarının piksel-tabanlı sınıflandırma sonucu ile değerlendirilmesi.	91

ŞEKİLLER DİZİNİ (devam ediyor)

<u>No</u>	<u>Sayfa</u>
Şekil 4.50 Bina sınıf türüne ait arazi noktalarının nesne-tabanlı sınıflandırma sonucu ile değerlendirilmesi.	92
Şekil 4.51 Uydu görüntüsünün 27.07.2016 tarihli Google Earth görüntüsü ile arasındaki zamansal değişimi.	93



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 3.1 Sınıflandırma hata matrisi.	37
Çizelge 4.1 GeoEye-1 uydu görüntüsünün teknik özellikleri	43
Çizelge 4.2 Piksel-tabanlı sınıflandırma için Kappa ve toplam doğruluk değerlendirme sonuçları.	55
Çizelge 4.3 GeoEye-1 uydu görüntüsü için segmentasyon parametreleri.	56
Çizelge 4.4 Nesne-tabanlı sınıflandırmaları için Kappa ve toplam doğruluk değerlendirme sonuçları.	67
Çizelge 4.5 Piksel ve nesne-tabanlı sınıflandırma sonuçlarının karşılaştırılması (%).	68
Çizelge 4.6 Referans vektör veri (uydu görüntüsü üzerinden elle sayısallaştırma) ve meşcere haritasına ait vektörleştirme sonuçlarının alan cinsinden değerlendirilmesi ve karşılaştırılması.	77
Çizelge 4.7 Referans vektör veri (uydu görüntüsü üzerinden elle sayısallaştırma) ve nesne-tabanlı sınıflandırmaya ait vektörleştirme sonuçlarının alan cinsinden değerlendirilmesi ve karşılaştırılması.....	84
Çizelge 4.8 1/25000 ölçekli meşcere haritası ve nesne-tabanlı sınıflandırma sonuçlarının referans vektör veri ile karşılaştırılması.	86
Çizelge 4.9 İbrelili sınıf türünün arazi değerlendirme sonuçları.	94
Çizelge 4.10 Yapraklı sınıf türünün arazi değerlendirme sonuçları.....	95
Çizelge 4.11 Tarım alanı sınıf türünün arazi değerlendirme sonuçları.	96
Çizelge 4.12 Açık alan sınıf türünün arazi değerlendirme sonuçları.	97
Çizelge 4.13 Bina sınıf türünün arazi değerlendirme sonuçları.	98
Çizelge 4.14 Tüm sınıf türlerinin arazi değerlendirme sonuçlarının karşılaştırılması (%).	99



SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

N_i	: Bant sayısı
μ_i	: Ortalama değer
V_i	: Kovaryans matrisi
f	: Objeye/ spektral birleşim değeri
h_{color}	: Spektral homojenite
h_{shape}	: Şekilsel heterojenite
w_c	: Spektral bant için kullanıcı tarafından belirlenen ağırlık katsayısı
σ	: Banttaki spektral değerlerin standart sapması
n_i	: Görüntü nesnesindeki piksel sayısı
$w_{compact}$: Kullanıcı tarafından verilen kompaktlık katsayısı
$h_{compact}$: Görüntü objesi üzerinden hesaplanan kompaktlık (Compactness)
h_{smooth}	: Görüntü objesi üzerinden hesaplanan pürüzsüzlük (Smoothness)
l_i	: Objenin fiili sınır uzunluğu yani çevresi
b_i	: Olası en büyük sınır çevresi
Δh_{renk}	: Spektral heterojenlik
$\Delta h_{şekil}$: Heterojenlik
$w_{renk}, w_{şekil}$: Ağırlık parametreleri
n_{nesne_1}	: Birleştirme için seçilen nesne
n_{nesne_2}	: Komşu nesne
$n_{merge} / n_{birleşim}$: Birleşim sonucu

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

$\Delta h_{\text{bütünlük}}$: Bütünlük
$\Delta h_{\text{yumuşaklık}}$: Yumuşaklık
b	: Kutunun çevre uzunluğu
r	: Hata matrisindeki toplam satır sayısı
x_{ii}	: i. satır ve sütundaki piksel sayısı
x_{i+}	: i. satırdaki toplam piksel sayısı
x_{+i}	: i. sütundaki toplam piksel sayısı
N	: Matrisin tamamındaki piksel sayısı

KISALTMALAR

AGA	: Anlık Görüş Alanı
AVHRR	: Advanced Very High Resolution Radiometer-Yüksek Çözünürlüklü Radyometre
CBS	: Coğrafi Bilgi Sistemi
CCD	: Charge Coupled Device – Yüklenme İliştirilmiş Aygıt
DGNSS	: Differential Global Navigation Satellite System- Diferansiyel Küresel Navigasyon Uydu Sistemleri
E	: Elektriksel alan
ED50	: EUROPEAN 1950
EMR	: Elektromanyetik radyasyon
EMS	: Elektromanyetik spektrum
GD	: Genel Doğruluk - Overall Accuracy(OA)
GNSS	: Global Navigation Satellite System - Diferansiyel Küresel Navigasyon Uydu Sistemleri
GSD	: Ground Sampling Distance -
ITRF96	: International Terrestrial Reference Frame- Uluslararası Yersel Referans Sistemi
k	: Kappa Değeri
KD	: Kullanıcı Doğruluğu -User Accuracy (UA)
M	: Manyetik alan

SİMGELER VE KISALTMALAR DİZİNİ (devam ediyor)

ÜD	: Üretici Doğruluğu - Producer Accuracy (PA)
RADAR	: Radio Detection and Ranging
SYM	: Sayısal Yükseklik Modeli
UTM	: Universal Transvers Merkator-Ulusal Merkatör Projeksiyonu
WGS84	: World Geodetic System
YKN	: Yer Kontrol Noktası
YÖA	: Yer Örnekleme Aralığı





BÖLÜM 1

GİRİŞ

Harita üretim süreci hem yoğun emek isteyen hem de zaman alan bir süreçtir. Altlık olarak kullanılan uydu görüntüleri veya hava fotoğraflarının dışında, raster haritalar ve detay bilgisi içeren başka vektör verilerin yardımcı kaynak olarak kullanımı ile başlayan ve birçok adımı içinde bulunduran bu süreç, detay tanımlamak için çok fazla zaman almaktadır. Bu süreçte kullanıcı, mevcut veriler dahilinde kişisel deneyimine dayanarak göz ile sonuç ürün üretmektedir. Ancak günümüzde gelişen uzaktan algılama teknolojileri ile detay tanımlamaya ilişkin yansıma değerleri de göz önünde bulundurularak çıplak göz ile elde edilemeyen birçok bilginin kolaylıkla tespit edilebileceği görülmüştür. Yüksek çözünürlüklü uydu görüntüleri elde etmeyi sağlayan yeni uydu sensörleri ile büyük ölçekli haritaların yapımına da büyük ölçüde katkı sağlanmıştır (Holland et al. 2006).

Ülkemizde ormancılık alanında yapılan çalışmalarda altlık olarak yersel ölçümlerle yapılan veriler kullanılmaktadır. Ormanlar doğal nedenler, insan müdahalesi gibi nedenlerden ötürü zaman içinde değişim gösterirler. Zaman içinde meydana gelen bu değişiklikler için haritaların belirli sürelerde yenilenerek güncel tutulmaları gerekmektedir. Haritaların yenilenmesi için zaman, maliyet ve iş gücü olarak fazla yüklü olan yersel ölçümler yerine uzaktan algılama verileri ile her açıdan tasarrufa gidileceği düşünülmektedir (Yurtseven 2008). Uzaktan algılama verileri orman yer örtüsünün değişimi, izlenmesi ve değerlendirilmesi açısından güncel bilgiye doğru, güvenilir ve daha kolay yoldan elde edilebilir sonuçlar üretilmesini sağlar. Günümüze kadar kullanılan ve halihazırda hala kullanılmaya devam etmekte olan hava fotoğrafları da ormancılık çalışmalarının önemli bir kısmında rol oynamaktadır (Sandmann and Lertzman 2003).

Günümüzde gelişen teknoloji ile uydu ve algılayıcı sistemlerindeki gelişim mekânsal, zamansal, spektral ve radyometrik çözünürlüklerine de başarılı bir şekilde yansımıştır. Bu gelişmeler ile birlikte hava fotoğraflarından çok daha fazla bilgiye sahip olunabileceği de ortaya

çıkmiştir. Ormancılık faaliyetlerinde gelişen teknolojinin kullanılması çalışmaların başarısına büyük ölçüde yansımıştır. Bugün gelinen noktada gelişmiş ülkelerin ormancılık faaliyetlerinde uzaktan algılama ve CBS'nin ortak olarak kullanıldığı görülmektedir. Bu nedenle, ülkemizde ormancılık faaliyetlerine kolaylık sağlayan ve sorunlarına çözüm üreten, CBS'nin temel olacağı bir orman bilgi sisteminin oluşturulması, ormancılık çalışmalarına yeni bir boyut kazandıracaktır (Koç 1995 b).

Uzaktan algılama çalışmaları kapsamında konumsal detayların güncellenebilir ve daha doğru sonuçlarla üretilmeleri için yeni görüntü yorumlama teknikleri geliştirilmiştir. Ormanlık alanların belirlenmesi, değişim analizleri, şehirselleşme ve değişimler, tarım alanlarının izlenmesi gibi daha birçok çalışma için uydu görüntüleri ve hava fotoğrafları üzerinden analizler yapılabilmektedir. Bu amaçla temel görüntü işleme tekniklerine dayanan yarı ve tam otomatik olarak görüntü değerlendirilmeleri için çeşitli sınıflandırma teknikleri kullanılmaya başlanmıştır.

Uzaktan algılama çalışmalarında kullanılan sınıflandırma yaklaşımları piksellerin istatistiksel analizlerine bağlıdır. Bu analizlerin sonuçlarına bakıldığında genel bir yaklaşım olarak en uygun sonuçların düşük çözünürlükteki görüntülerle çalışılırken alındığıdır. Uydu teknolojilerinin gelişmesiyle yüksek çözünürlüklü görüntüler üretildiğinde, doğru orantılı olarak daha doğruluklu sonuçlar alınacağı düşünülmüştür. Fakat çalışılan alan arazi örtüsünü içeriyorsa bu durum beklentiyi karşılamamış, daha düşük çözünürlüklü görüntülerde başarılı sonuçlar alınmıştır. Yüksek çözünürlüklü uydu görüntüsü ile çalışıldığında elde edilen doğruluk ancak büyük ölçekli haritalara uygun sonuçlar vermiştir. Buna sebep olarak çözünürlük arttıkça sınıflar içindeki spektral varyans artmış ve spektral olarak arazi tiplerinin karışmış olması sınıflandırma da ayırt edilebilmeyi zorlaştırılabilmektedir (Shaban and Dikshit 2001).

Piksel-tabanlı sınıflandırma yaklaşımı semantik bilgiyi kullanmadığı için arazi örtüsünden gerçeğe yakın olarak sonuç elde etmek için pek uygun değildir. Sonuçlandırılan tematik haritalar tuz-biber etkisine maruz kalarak düşük doğrulukla üretilmektedirler. Arazi örtüsü ya fazla detay içermeden genel hatlarla belirtilir ya da düşük doğrulukla başka ilave detay haritaları ile oluşturulmaktadır (Franklin et al. 2003). Literatüre bakıldığında genel olarak piksel- tabanlı sınıflandırma yöntemleri kullanılırken görüntünün yüksek çözünürlüklü olmaması gerektiği görülmüştür (Schiewe et al. 2001). Bu duruma alternatif çözüm olarak sınıflandırmaya mekânsal özelliklerin dahil edilmesi olacaktır. Nesne-tabanlı sınıflandırma ile bu tür mekânsal

bilgiler sınıflandırma işlemine dahil edilmektedir. Bu sınıflandırma yaklaşımı ekolojik ve coğrafi gibi çevre disiplinlerini de kullanarak sonuç ürün elde etmektedir. Bu yaklaşım sadece piksellerin kullanılması yerine daha spesifik ve anlamlı nesnelere oluşturulması istenilen çalışmalarda kullanılması uygun olmaktadır (Blaschke and Strobl 2001).

Nesne-tabanlı sınıflandırma yaklaşımı genel olarak piksellerin dışında anlamlı nesnelere ve karşılıklı ilişkilerle görüntü yorumlanması için gerekli bazı bilgilerin kullanılması durumundan ortaya çıkmıştır. Nesne-tabanlı sınıflandırma yaklaşımında sınıflandırma aşaması, komşu piksellerin gruplandırılmasının sınıflandırmanın sonraki adımında anlamlı bölgelere dönüştürülmesi ile başlar. Bu şekilde yapılan segmentasyon ve topoloji oluşumu, çözünürlüğe ve gerçek dünya nesnesine benzer sonuç elde etmek için ölçeğe göre belirlenmelidir. Segmentasyon işlemi ile sadece tekil pikseller sınıflandırılmakla kalmaz, bir önceki segmentasyon adımıdaki homojen görüntü nesnelere de ortaya çıkmış olur. Segmentasyon farklı çözünürlüğe sahip görüntülere uygulanabilirken, nesnelere kategorilere de ayrılmasına izin verir. Bu aşamadan sonra oluşturulmak istenen sınıflar çıkartılır ve segmentasyon sonrası oluşan nesnelere bu sınıflara dahil edilerek kural seti ya da çoklu segmentasyon yönteminden biri seçilerek sonuç ürün elde edilir (Batz et al. 2004).

Literatürde ormanlık alanlarda yapılan çalışmalara bakıldığında kullanılan uydu görüntüleri arasındaki farklar değerlendirilmiştir. SPOT 4 görüntü verisinin geometrik çözünürlüğü LANDSAT görüntü verisine göre yüksek olduğu için çalışmalarda sınıflandırma sonuçları da LANDSAT'a göre daha olumlu olmuştur. Bunu karşılık geometrik çözünürlüğü SPOT 4 'ten daha yüksek olan BİLSAT görüntü verisi ile sınıflandırma sonuçları karşılaştırıldığında görsel detayların belirlenmesinin daha zor olduğu anlaşılmıştır. Neden olarak, BİLSAT görüntü verisinin geometrik çözünürlüğü yüksek olsa da radyometrik çözünürlüğünün düşük olması gösterilmiştir. Özellikle meşcere içindeki ağaçların orman yollarını kapattığı alanlarda bu iki sınıf için ayırt edilebilmeyi zorlaştırmıştır (Ateşoğlu 2007).

Görüntü verisinden elde edilecek bilgi geometrik ve radyometrik çözünürlüğe bağlı olduğu kadar spektral çözünürlüğe de bağlı olduğu yapılan çalışmalarla sonuçlandırılmıştır. Spektral çözünürlük özellikle meşcere tiplerinin ayırımında büyük rol oynamaktadır. Spektral ayırımın yapılması ile orman yer örtü tipleri, spektrumun yakın kızılötesi bölgesinde olumlu sonuçlar vermektedir. LANDSAT-TM ve ETM uydu verilerinin 4. Bandı, SPOT uydusunun 3. Bandı

yakın kızılötesi bölgede algılama yapabilmekte olup ormancılık çalışmalarında sıkça tercih edilen uydu verileridir (Lillesand and Kiefer 2000).

WorldView-2 uydusuyla yapılan bir çalışmada uydu verisinin sunduğu yüksek konumsal çözünürlük ile ibreli ağaçların tepe taçlarının sınıflandırma sonuçlarında yüksek başarılar elde edilmiştir. Ancak spektral karakteristiklerinin ihtiyacı tam olarak karşılamadığından dolayı çalışma alanı içerisindeki Karaçam ve Sahil Çamı meşcerelerini istenilen başarıda sınıflandıramamıştır. Tür-alan envanterlerinin çıkartılması gibi daha kapsamlı bir çalışma yürütülmek istenildiğinde WorldView-2 uydu verisine ek olarak spektral veriyi destekleyebilecek verilerin seçilmesi gerektiği sonucuna da varılmıştır (Yurtseven 2012).

Uzaktan algılama verileri üzerinden meşcere tiplerinin sınıflandırılarak ormancılık çalışmalarına altlık olması yıllardır yapılmaktadır. Yukarıda belirtildiği gibi gelişen teknoloji ile yüksek doğruluklu uzaktan algılama verilerinin kullanımları sayesinde orman örtü tiplerinin elde edilebilirliği ve değişimleri daha başarılı sonuçlarla araştırılabilmektedir.

1.1. ÇALIŞMANIN AMACI

Yapılan bu tez çalışmasında birden fazla amaç belirlenmiş olup bu doğrultuda çalışmalar yapılarak sonuçlar elde edilmiştir. Gerçekleştirilen bu amaçlar aşağıda belirtilmiştir.

- Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsünün sağladığı bilgi içeriğini belirlemek, çalışmadaki sınıflandırma yöntemleri üzerinde olumlu ve olumsuz başarısını, başka çalışmalara altlık olabilmesi açısından örnek olarak gösterilmesi.
- Çalışmada detay tespiti için kullanılan piksel ve nesne-tabanlı sınıflandırma yaklaşımlarının araştırılması ve böyle bir çalışma için öneminin gösterilmesi.
- Ormancılık çalışmalarında nesne-tabanlı sınıflandırma yaklaşımı ile piksel-tabanlı sınıflandırma yaklaşımlarının sonuçlarının analiz edilmesi ve uygun yöntemin belirlenmesi.
- Çalışma alanında belirlenen beş sınıf tipi içinden orman örtü tipi olan “ İbreli ve Yapraklı” sınıf türlerinin dışındaki sınıfların böyle bir çalışmada başarılarının belirlenmesi ve gösterilmesi.

- Elle vektörleştirilen GeoEye-1 uydu görüntüsünün diğer vektör verilerle karşılaştırılarak başarı sonuçlarının alan cinsinden belirlenmesi, birbirlerine göre avantaj ve dezavantajlarının gösterilmesi.
- Arazi çalışması ile nokta bazında diğer vektör verilerle karşılaştırılmaları yapılarak birbirlerine göre üstünlükleri, başarısızlıkları ve zamansal değişimden kaynaklı farkın oluşturduğu sonuçların gösterilmesi.
- Yapılan bu değerlendirme ve sonuçlara görsel ve sayısal olarak bakıldığında ormancılık çalışmalarında yüksek doğruluk üreterek detayların tespiti, yeni haritaların üretimi, haritaların revize edilmeleri gibi ihtiyaçların, hangi sınıflandırma yaklaşımının sağlayacağını gösterilmesi olmuştur.

1.2. ÇALIŞMANIN KAPSAMI

Tez toplam 5 farklı bölümden oluşmaktadır. Aşağıdaki kısımda her bir bölümde ele alınan konulara ilişkin kısa ve öz bilgiler verilmiştir.

İlk bölüm tezin “Giriş” kısmını oluşturmaktadır. Konuya ilişkin literatür araştırması yapılmış olup, tezin amaç ve kapsamı hakkında bilgiler verilmiştir.

İkinci bölüm “Uzaktan Algılamada Temel Kavramlar” kısmından oluşmaktadır. Bu kısımda ilk olarak elektromanyetik enerji ve elektromanyetik spektrum hakkında bilgiler verilmiştir. Algılayıcı ve hedef arasında kalan atmosferin neden olduğu atmosferik etkilerin görüntüler üzerinde yarattığı olumsuzluklardan bahsedilmiş olup bu durumun etkilerinin görüntünün geometrik düzeltilmesi ve birçok pan-sharp yöntemi kullanılarak geometrik ve radyometrik olarak zenginleştirilmesi anlatılarak devam edilmiştir. Nesnelerin spektral özelliklerine göre elektromanyetik spektrumun farklı bölgelerindeki yansıtım değerlerinden bahsedilmiş olup, çalışma ormanlık alanda yapıldığı için yeşil bitkilerin yakın kızıl ötesi bölgede az miktarda soğurularak yansıma değerlerinin yüksek olduğundan bahsedilmiştir. Diğer bir önemli konu algılayıcı türleridir. Algılayıcı türleri sınıflandırılmış ve detaylı olarak özellikleri açıklanmıştır. Son olarak görüntüler üzerinde etkileri gözle görülebilen ve çalışmanın sonucunu büyük ölçüde etkileyebilen çözünürlük kavramı anlatılmıştır.

Üçüncü bölümde “Uzaktan Algılamada Görüntü Sınıflandırma Teknikleri” başlığı altında sınıflandırma yaklaşımları hakkında literatür araştırması sonucu bilgiler verilmiştir. Piksel-

tabanlı sınıflandırma yaklaşımı ve yöntemlerinden bahsedilmiş olup, uygulamada kullanılan yöntem, nedenleriyle birlikte açıklanmıştır. Piksel-tabanlı sınıflandırmaya göre daha üstün olan nesne-tabanlı sınıflandırma yaklaşımı, segmentasyon ve sınıflandırma yöntemleri olmak üzere bu kısımda detaylı bir şekilde anlatılmıştır.

Dördüncü bölümdeki “Uygulama” kısmı detaylı bir şekilde görsel ve sayısal sonuçlarla anlatılmıştır. Bu bölümde çalışma alanı, uydu görüntüsü ve kullanılan yazılımlar hakkında bilgilendirme yapılmıştır. Üçüncü bölümde açıklaması yapılan piksel ve nesne-tabanlı sınıflandırma yaklaşımları GeoEye-1 uydu görüntüsü üzerinde uygulanarak sonuç ürünler elde edilmiştir. Bu iki sınıflandırma yaklaşımının görsel ve sayısal sonuçlarına bakılarak nesne-tabanlı sınıflandırma yaklaşımının çalışmalar için kullanılabilir olduğu sonucuna da varılmıştır. Elde edilen sınıflandırma sonuçlarının vektörleştirilmeleri CBS’ye aktarılmış ve diğer vektör verileriyle karşılaştırılmak üzere hazır hale getirilmiştir. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve araziden alınan 150 adet koordinatlı nokta diğer vektör verileriyle karşılaştırılarak iki farklı değerlendirme yapılmıştır. İlk değerlendirme elle vektörleştirilmiş uydu görüntüsünün 1/25000 ölçekli meşcere haritası ve nesne-tabanlı sınıflandırma sonuçları ile karşılaştırılması olmuştur. Sonuçlar alan bazında yapılmış olup, görsel ve sayısal olarak başarıları ve başarısızlıkları değerlendirilmiştir. İkinci değerlendirme araziden alınan her sınıf tipine ait toplamda 150 adet noktanın elle vektörleştirilmiş uydu görüntüsü, 1/25000 ölçekli meşcere haritası, piksel ve nesne-tabanlı sınıflandırma sonuçlarıyla karşılaştırılmaları olmuştur. Karşılaştırma nokta bazında yapılmış olup her bir vektör verinin araziden alınan noktalara göre başarısı ve başarısızlıkları görsel ve sayısal olarak nedenleriyle birlikte anlatılmıştır. CBS altında yapılan bu detaylı analiz ve sorgulamalar kullanılan verilerin güncelliğini ve kullanım doğruluğunu ortaya koymakla birlikte, ormancılık çalışmalarına altlık oluşturabilecek haritaların üretiminde hangi sınıflandırma yönteminin kullanılabileceğini nedenleriyle birlikte göstermiştir.

Beşinci bölüm “Sonuç ve Öneriler” kısmından oluşmaktadır. Bu bölümde çalışma kapsamında yapılan uygulamalar, sonuçları, değerlendirilmeleri ve analizlerinden yararlanarak elde edilen bulgular özetlenerek değerlendirilmiştir.


BÖLÜM 2

UZAKTAN ALGILAMADA TEMEL KAVRAMLAR

Uzaktan algılama kavramı genel anlamda herhangi bir fiziksel temasta bulunmaksızın nesnelere hakkında bilgi edinme tekniğidir (Lillesand et al. 2007). Uzaktan algılama konusunda gelişen teknoloji ile yeryüzünden yansıyan ve yayılan enerjinin algılanması, kaydedilmesi, işleme ve analiz etme gibi özellikler kolaylıkla yapılabilmektedir. En önemli kaynağını uydular ve hava araçları üzerinde taşınan aletlerle alınan uydu görüntüleri oluşturmaktadır. İstenilen nesneden yayılan elektromanyetik enerji ile nicel sonuçların alınması da uzaktan algılama sistemlerinin kullanılmasında büyük bir avantaj sağlamaktadır.

2.1. ELEKTROMANYETİK ENERJİ VE ELEKTROMANYETİK SPEKTRUM

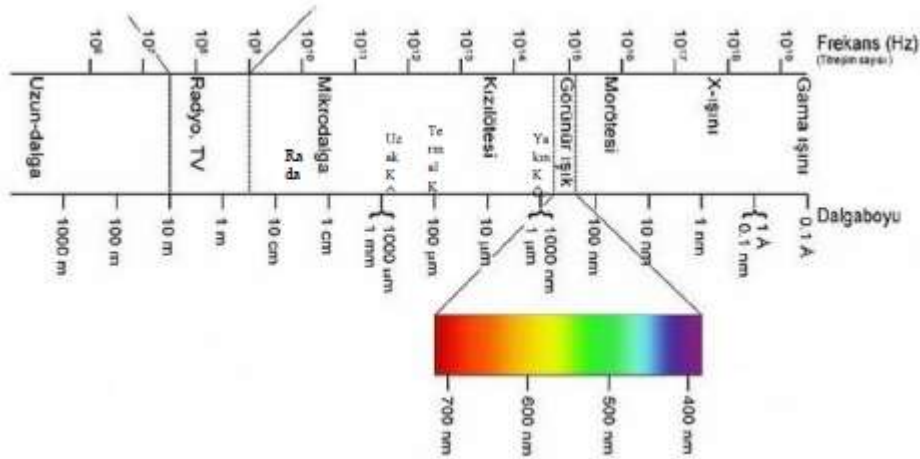
Uzaktan algılamada objelerin görüntülenebilmeleri için ya ışık enerjisi göndermeleri ya da aydınlatılmaları için enerji kaynağına sahip olmaları gerekmektedir. Uzaktan algılamanın en önemli enerji kaynağı güneştir. Güneş enerjisi elektromanyetik dalgalar halinde yeryüzüne iletilir. Enerjinin ışık yolu elektromanyetik radyasyon (EMR) ile taşınır. Şekil 2.1'deki EMR'de elektriksel alan (E) ve elektriksel alana dik yönde oluşan manyetik alan (M) ile ifade edilmektedir. Burada ışık hızında hareket eden sinüzoidal dalgaların ikisi de yayılma yönüne dik açı ile gelmektedir.



Şekil 2.1 Elektromanyetik dalgalar.

Dalga uzayda yayılan bir titreşimdir ve görüntüleme sistemlerinin yeryüzünden yansıyan ışını optik dalga boyunda kaydetmesi ile oluşur. Gelen dalganın tepesi ile ardından gelen dalganın tepesinin uzaklığına dalga boyu denir. Dalganın alabileceği maksimum yüksekliği genişlik, saniyede oluşan dalga boyu sayısı da frekanstır. Elektromanyetik spektrum (EMS) 3×10^8 m/sn hızla hareket edebilen ve dalga boyu uzunluğunun nanometrelerden kilometrelere kadar uzanan enerji ortamıdır. EMS süreklidir ve farklı bölgelerinde algılama yapan algılayıcılar ile yeryüzü hakkında çeşitli bilgiler edinmeyi sağlar (Sesören 1999).

Elektromanyetik enerji, dalgaları kullanarak geniş bir spektrumda yayılır. Şekil 2.2’de elektromanyetik spektrum ve dalga boylarının bölgeleri gösterilmektedir. İnsan gözü, küçük bir bölge olan görünür ışık bölgesine duyarlıdır. Görünür dalga boyu $0.4-0.7 \mu m$ arasındadır. Bu aralıkta $0.455-0.492 \mu m$ mavi, $0.492-0.588 \mu m$ yeşil ve $0.588-0.720 \mu m$ kırmızı renge karşılık gelen dalga boylarıdır. Toprak ve kimyasal araştırmalar için $0.4-1.5 \mu m$, bitkilerdeki klorofille duyarlı kızılötesi ışınlar $0.7-3.0 \mu m$ dalga boyları arasındadır. $3.0-15 \mu m$ dalga boyundaki termal bantlar yeryüzü ısısına duyarlıdır. Özellikle mineral, petrol gibi jeolojik çalışmalar da kullanılır. Yükseklik ve nem ile ilgili çalışmalar için de daha çok $1.0-100 \mu m$ dalga boyundaki mikrodalga ışınları kullanılmaktadır (Lillesand et al. 2000).



Şekil 2.2 Elektromanyetik spektrum.

2.2. ATMOSFERİK ETKİLER

Güneş ışınları dünyaya ulaşırken atmosfer tabakasından geçer ve geçiş sırasında bazı etkilere maruz kalırlar. Işınların bir kısmı yeryüzüne ulaşırken soğurular, bir kısmı da yansyarak

atmosferden geçer ve algılayıcıya ulaşır. Kısacası uzaktan algılama uygulamalarında algılayıcı tarafından algılanan veriler, algılayıcı ile hedef arasında kalan atmosfer etkileri denilebilmektedir (Maktav ve Sunar 1991).

Atmosfer verileri, enerjinin soğurulması ve saçılması olmak üzere iki şekilde etkileyebilir. Saçılım ışınların atmosferden geçerken taneciklerinden yansınması ve kırılması ile oluşur. Bu tanecikler toz tanecikleri, su damlacıkları ve gaz molekülleridir. Bu konuyla ilgili genel düşünce saçılan ışının zayıflamadığı sadece yeniden yönlendiği yönündedir. Bu yönlendirme ışının dalga boyuna bağlı olarak değişmektedir. Uzaktan algılamada saçılımın etkisi, enerjinin algılayıcı tarafından tamamen kaydedilememesidir. Teorik olarak incelendiğinde saçılım, ışının dalga boyu ile saçılma neden olan taneciklerin büyüklüğü arasındaki bağlantıya göre literatürde Rayleigh saçılımı, Mie saçılımı ve Seçici olmayan saçılım olmak üzere üçe ayrılmıştır.

2.2.1. Görüntünün Geometrik Düzeltilmesi

Geometrik distorsiyonların nedenleri platformun yüksekliği, konumu, hızı, yörünge sapması gibi kalibrasyon bilgileri ile düzeltilebilen sistematik hata (tekrarlı, düzenli) olabilirken, görüntü üretiminden önce bilinmeyen yer kontrol noktaları (YKN) ve sayısal yükseklik modeli (SYM) verileri kullanılarak giderilebilen sistematik olmayan (rastgele, düzensiz) hatalar da olabilmektedir. Sistematik hatalar kalibrasyon bilgileri ile düzeltilebilirken, sistematik olmayan hataların düzeltilebilmesi için bir çok matematiksel modeller oluşturulmuştur. İki ya da üç boyutlu bu modeller parametrik ve parametrik olmayan modeller olarak ikiye ayrılırlar. Kısaca açıklanacak olursa parametrik olmayan yaklaşımlarda algılayıcı sisteme ait parametreler mevcut değildir ve çözüm için de görüntüleme geometrisi dikkate alınmaz. Parametrik modeller ise görüntüleme geometrisiyle ilgili bilgileri içeren ve bu sayede parametrik olmayan modellere göre üst düzey sayılan modellerdir. Bu model YKN doğruluklarına bağlıdır ama dağılımlarıyla ilgili bağılıkları yoktur. Parametrik olmayan modellere göre de daha az sayıda YKN noktasına ihtiyaç duyulur (Tountin 2003).

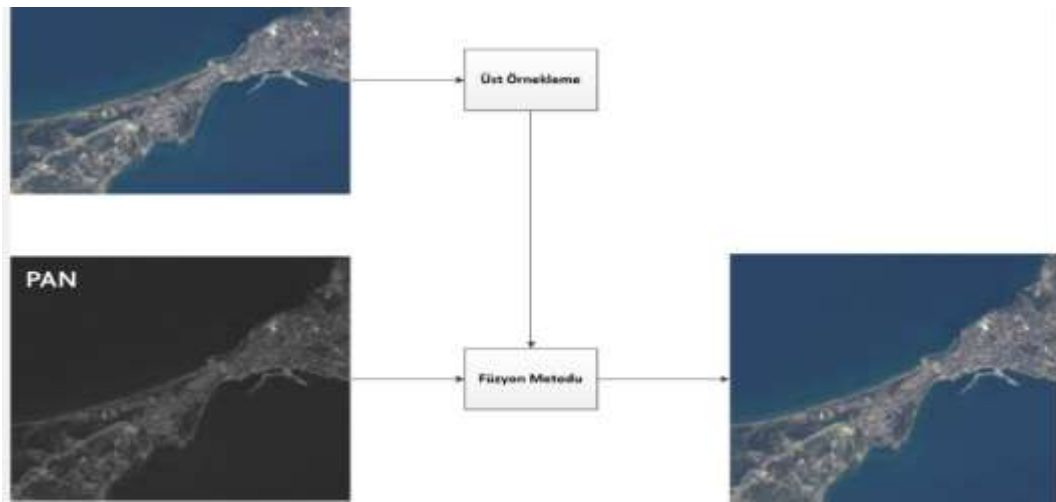
2.2.2. Görüntünün Zenginleştirilmesi

Görüntünün fiziksel özelliklerinin daha anlaşılabilir ve yorumlanabilir olması, çalışmada istenilen sonuçların doğruluklarının nitel ve nicel olarak yüksek olması gibi sebeplerden ötürü sayısal matrisler kullanılmaktadır. Uzaktan algılama uygulamalarında görüntü içeriklerinin

zenginleştirilmesi için genel olarak kullanılan yöntemler konumsal ya da spektral dönüşümlerdir.

Konumsal dönüşümdeki amaç, konumsal filtreleme ile dijital görüntülerdeki bilgiyi değiştirmek ya da dışarıya çıkartmaktır. Konumsal filtreleme, görüntüdeki nesnelerin fiziksel özelliklerinin; görüntüdeki kenar çizgilerinin daha net olarak gösterilmesi, yok edilmesi ya da farkların vurgulanması gibi daha detaylı ayırım yapılarak görsel yorumlanmayı arttırmak amacıyla, sayısal filtreleme matrisleri kullanılarak yapılmaktadır (Sunar 2011).

Spektral dönüşümlere en genel örnek görüntü birleştirmedir. Görüntü birleştirme, aynı alan için alınmış iki görüntünün geometrik, radyometrik ve spektral çözünürlük gibi temel özellikleri farklı olabilen, aynı veya farklı tarihlerde alınmış en az iki görüntünün birleştirilerek yeni görüntünün elde edilmesidir (Şekil 2.3). Oluşan yeni görüntü, birleştirilen iki görüntüye göre üstündür. Literatürde, pan-sharp, pan-shared, pan-sharpening, pankeskinleştirme, görüntü birleştirme, görüntü kaynaştırma olarak da yer almaktadır. Bu işlemde amaç, kaynaştırma sonucunda düşük çözünürlüklü çok bantlı görüntünün, geometrik çözünürlüğünü olabildiğince pankromatik görüntüye yaklaştırmaktır (Pohl and Van Genderen 1998). Çalışmanın konusu ve görüntü içeriğinden alınacak bilgi türüne göre uygulanması kullanıcı tarafından karar verilmektedir.

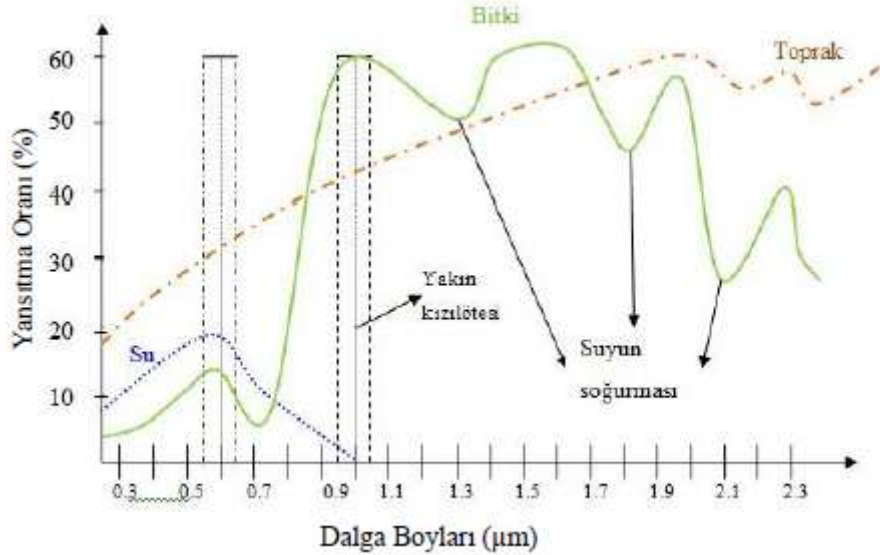


Şekil 2.3 Pan-sharp işlemi.

2.3. NESNELERİN SPEKTRAL ÖZELLİKLERİ

Yeryüzündeki her nesne kendine özgü yansıtım değerine sahiptir. Buna nesnenin imzası ya da karakteristiği de denilir. Uzaktan algılama uygulamalarında uydu görüntüleri üzerinden nesnelerin algılanmaları, ayırt edilmeleri ve yorumlanabilmeleri için spektral özelliklerinin bilinmesi gerekmektedir. Görüntüdeki bitki örtüsü, toprak çeşitliliği, su gibi yüzey özelliklerinin spektral yansıma değerleri bilinirse, duyarlı olduğu banda göre analiz ve yorumlanması da daha kolay olacaktır.

Yeşil bitkiler yapılarında bulundurdukları klorofilden ve yakın kızıl ötesi bölgede az miktarda soğurmalarından dolayı yansıma değerleri yakın kızıl ötesi bant için büyük ölçüde artmaktadır. Bu yüzden ormancılık çalışmalarında kullanılan uydu görüntülerinde bu bant öne çıkarılmaktadır. Orta kızıl ötesi bölgede su belirli dalga boylarında enerjiyi fazla soğurur ve yeşil yapraklardaki fazla nem miktarının bulundurduğu su miktarından dolayı da bu bölgede baskındır. Mavi ve kırmızı bant için durum tam tersidir ve en yüksek soğurma değerini yakın kızıl ötesi bant için alır. Görünür dalga boylarında yeşil yaprağa gelen enerjinin büyük bir kısmı soğurulur ve yapraktan küçük bir kısım geçer. Genç ve sağlıklı yeşil yaprakların canlı ve gerçeğe yakın gözükmelerinin sebebi yeşil dalga boyundaki bu düşük soğurmadır (Şekil 2.4).



Şekil 2.4 Farklı yer örtü tipleri için genelleştirilmiş spektral yansıtım grafiği.

Bitkiler klorofilden başka karoten (sarı pigment), ksantofil (sarı pigment) ve antosyanini (kırmızı pigment) yapılarında bulundururlar. Karoten ve ksantofiller daha çok yeşil yapraklarda

bulunur ama sadece mavi bant için soğurmaya sahiptirler. Bitkiler canlılığını kaybettikçe ya da yaşlandıkça klorofil miktarları giderek azalır buda karoten ve ksantofillerin artmasına neden olur. Daha çok sonbaharda görülen durumun açıklaması da bu şekildedir. Aynı şekilde azalan klorofil miktarı ile antosyanin pigmentleri çoğalır ve yapraklar artık açık kırmızı olarak görülür (Maktav ve Sunar 1991).

2.4. ALGILAYICI TÜRLERİ

Algılayıcılar, farklı şekillerde sınıflandırılabilirler. Genel bir sınıflandırma, algılanan enerji kaynağına göre yapılan sınıflandırmadır ki bu durumda pasif ve aktif algılamadan söz edilebilir.

Pasif Algılayıcılar: Doğal kaynaklı elektromanyetik enerjinin yayılımını ve yansıtımını algırlarlar. Pasif algılayıcılar tarafından algılanan en bilindik enerji kaynağı güneş ışınlarıdır. Pasif algılayıcılar sadece nesneden yansıyan veya yayılan ışını kullandıkları için her türlü hava koşulunda kullanışlı olamayabilmektedirler.

Aktif Algılayıcılar: Yapay bir enerji tarafından üretilen enerjinin yayılım ve yansıtımını algırlarlar. Aktif algılayıcılar kendi enerjilerini üretebildiklerinden herhangi bir hava koşulundan etkilenmezler. Aktif algılayıcılara örnek olarak Radio Detection and Ranging (RADAR) verilebilir. Radarlar prensip olarak, sistemin ürettiği elektromanyetik dalgayı belirli bir alana göndererek ve saçılan dalgaları toplayarak, elde edilen bilgiler üzerinden veri çıkarmaya dayanır (Polat 2015).

- 1- Çerçeve Görüntüleme Sistemleri
- 2- Satır Tipli Görüntüleme Sistemleri
 - 2.a- Ayna Tarama görüntüleme sistemleri
 - 2.b-Doğrusal dizi görüntüleme sistemleri
- 3- Mikro-dalga görüntüleme sistemleri

2.4.1. Doğrusal Dizin (Pushbroom) Görüntüleme Sistemleri

Çalışmada kullanılan GeoEye-1 uydu görüntüsünün sahip olduğu pushbroom görüntüleme sistemi, odak düzlemine yerleştirilen bir dizi dedektörden oluşmaktadır. Doğrusal dizini oluşturan her bir dizideki dedektörün boyutu merceğin odak uzaklığı ile birlikte görüntülenen alandaki her bir piksele karşılık gelen nesnenin boyutunu belirlemektedir (Şekil 2.5). İçerisinde

bulundurduğu çok sayıdaki Charge Couple Device (CCD)'lerle bu algılayıcı sistem, yeryüzündeki nesneden gelen her bir elektromanyetik enerjiye karşı CCD elemanına bir elektrik yükü üretilir. Dedektörler arasındaki bu sabit ilişkiden dolayı da geometrik doğruluğun yüksek olduğu belirlenmiştir (Büyüksalih 2011). Bu algılayıcılarda en iyi bilinen örnekler SPOT, IKONOS, Quickbird-2, OrbView, GeoEye, Worldview-2 uydularındır.


Pushbroom algılayıcı sisteminin getirdiği olumlu yanlar aşağıda sıralanmıştır:

- Görüntülerde yüksek konumsal ve radyometrik çözünürlük sağlanması,
- Ağırlık ve boyut olarak hafif olmalarından dolayı daha az güç gerektirmeleri,
- Algılayıcı sistemi oluşturan sensörlerin sabit olmasından dolayı uzun ömürlü olmaları,
- Doğrusal dizi elemanları arasında sabit bir ilişki olmasından dolayı da geometrik bütünlüğün yüksek olmasıdır.

Yukarıda belirtilen olumlu yanları kadar aşağıda sıralandığı gibi olumsuz yanları da vardır:

- Doğrusal dizilerinin geometrik ve radyometrik açıdan kalibre edilmeleri oldukça zordur.
- Dizini oluşturan CCD dedektörlerinin spektral duyarlılığa yeterince sahip olmamaları.

Bu sıraladığımız olumsuz yanlara rağmen son zamanlarda yapılan uzaktan algılama çalışmalarında olumlu yanlarından dolayı çoğunlukla tercih edilmektedir (Topan 2004).



Şekil 2.5 Doğrusal dizi görüntüleme sistemi (Topan 2004).

2.5. UZAKTAN ALGILAMADA ÇÖZÜNÜRLÜK KAVRAMI

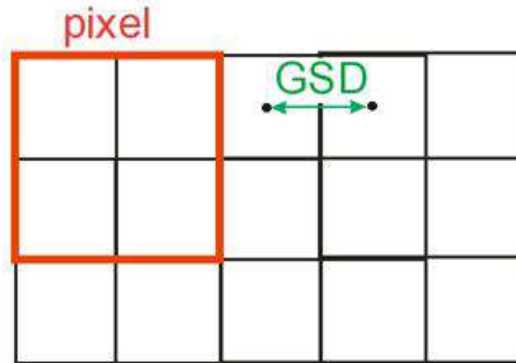
Çözünürlük, görüntüdeki bir pikselin yeryüzündeki karşılık geldiği alanın kalitesini temsil etmektedir. Piksel, görüntü matrisinin üzerinde oluşan ızgara biçimindeki küçük alanlar demektir. Çözünürlük kavramı da piksel sayısı ile doğrudan ilişkili olmaktadır.

Sayısal görüntüler, bir resmin modern çok bantlı tarayıcılar ve sayısal hava kameraları ile elde edilerek oluşmasıdır. Oluşan görüntünün gerçeği olabildiğince yansıtabilmesi gerekmektedir. Uzaktan algılama da bu ilişkilerin değerlendirilmesi için dört farklı çözünürlük kavramı mevcuttur. Bunlar, konumsal, spektral, radyometrik ve zamansal çözünürlüktür. Aşağıda her bir çözünürlük kavramı detaylı olarak anlatılmıştır.

2.5.1. Konumsal Çözünürlük


Görüntüdeki fark edilebilir, görülebilen en küçük detay boyutu, algılayıcının konumsal çözünürlüğü ile alakalıdır. Başka bir ifadeyle, bir görüntüleme sistemi tarafından farklı olarak kaydedilebilen iki nesne arasındaki en küçük uzaklık olarak tanımlanabilir ve amaca bağlı olarak değişik ölçütlerle belirlenebilmektedir (Topan 2004).

Bunlardan biri Ground Sampling Distance (GSD)- Yer Örnekleme Aralığı (YÖA), bir diğeri ise algılayıcının anlık görüş alanıdır (AGA). Yer örnekleme aralığı, komşu piksellerin merkezlerinin yeryüzündeki fiziksel karşılığına denk gelmektedir (Şekil 2.6). Genellikle cm. ve/veya m. cinsinden ifade edilmektedir.




Şekil 2.6 Yer örnekleme aralığı.

Anlık görüş alanı, görüntüyü oluşturan sistemdeki alıcının anlık görüş alanının yeryüzündeki karşılığıdır. Anlık görüş alanı; uzaktan algılama uydularındaki tarayıcı optiklerin gücünü ifade eder ve algılayıcı sensör ile algılanan yer yüzeyi anlamına gelmektedir. Uzaktan algılama da bir sensörün ya da alıcısının anlık görüş alanı açısaldır ve yeryüzündeki karşılığı da uydunun yüksekliğine bağlı olarak değişiklik göstermektedir. Bu büyüklük piksel boyutuna da denktir (Çölkesen 2009).



Şekil 2.7 Uzaktan algılama uyduları için anlık görüş alanının açısal ve uzunluk olarak ifadesi.

Şekil 2.7’de X-Y noktaları arasındaki alan, anlık görüş alanıdır ve uydu görüntüsünde yaklaşık bir piksele denk gelmektedir. Şekil 2.8’de aynı bölgeye ait farklı konumsal çözünürlüğe sahip üç uydu görüntüsü verilmiştir. Bunlardan Şekil 2.8a’nın anlık görüş alanı 1 metre, Şekil 2.8b’nin anlık görüş alanı 10 metre ve Şekil 2.8c’nin anlık görüş alanı 30 metredir. Yeryüzünde taranan anlık görüş alanları büyüdükçe konumsal çözünürlükte azalmıştır. Konumsal çözünürlüğü en yüksek olan Şekil 2.8a da görüntüdeki bütün detaylar net olarak görülebiliyorken diğer görüntülerde konumsal çözünürlüğün azalmasıyla detayların netliğinin giderek azaldığı görülmektedir.




Şekil 2.8 Konumsal çözünürlük kavramı. (a) 1 metre, (b) 10 metre, (c) 30 metre YÖA değerine sahip görüntüler.

2.5.2. Radyometrik Çözünürlük

Algılayıcılar tarafından elde edilen görüntünün elektromanyetik enerji miktarına duyarlılığı ya da görüntülenen alandaki enerji farklılıklarını seçebilmek ve kaydedebilmek radyometrik çözünürlüğü tanımlamaktadır. Kısaca radyometrik çözünürlük, objeleri ayırt etmek için kullanılan toplam renk tonu sayısıdır. Şekil 2.9’da olduğu gibi renkleri tonlandırmak ve derecelendirmek ne kadar yüksek olursa objenin ayırt edilmesi de o kadar kolay olmaktadır (Çölkesen 2009).

Uzaktan algılamada radyometrik çözünürlük; siyah ve beyaz renklerin arasındaki gri renklerin ölçülmesidir. Enerjinin radyometrik çözünürlüğü bitlik sistemde ölçülmektedir ve 2^b ile ifade edilerek sistemden sisteme değişen bir aralığa bölünerek sayısallaşmaktadır (Topan 2008). Bir bitlik bir sistem $2^1=2$ gri düzeyini ölçerken 8 bitlik sistem $2^8=256$ gri düzeyini kaydedebilmektedir. Siyah renk sıfıra, beyaz renk ise 255 değerine denk gelmektedir. Uzaktan algılama da kullanılan çoğu sistemde radyometrik çözünürlük 6 bit ya da 6 bitten daha fazladır.




Şekil 2.9 Radyometrik çözünürlük kavramı (a=2 bit, b=8 bit).

2.5.3. Spektral Çözünürlük

Spektral çözünürlük, bir algılayıcının elektromanyetik spektrumda kaydedebildiği dalga boyu aralığıdır. Genel olarak bantların sayısını, genişliğini, cismin yayılma, yansıma, geçirgenliği ve soğurmasını ifade eden kavramdır. Algılayıcılar da, meydana gelen bu spektral değişiklikleri fark edebilecek şekilde tasarlanmıştır. Görüntülerdeki ayrıntılar ve objeler çoğunlukla farklı dalga boyu aralıklarına yanıt verirler. Yani nesnelerin spektral özellikleri ile kendilerine has özellikleri arasında bir ilişki vardır. Her spektral bandın duyarlı olduğu elektromanyetik spektrum bölümü mevcuttur. Bu bölümlerde, başlangıç ve bitiş dalga boyları ile bant genişliği ve merkez frekansı şeklindedir (Şekil 2.11).

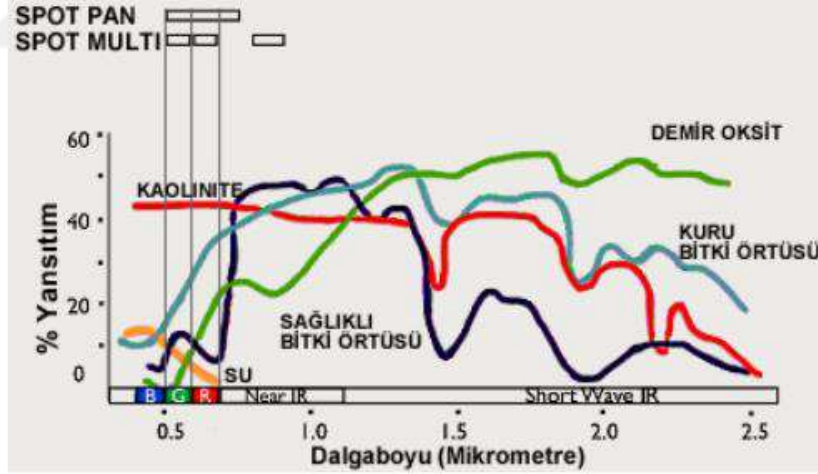
Daha iyi bir spektral çözünürlük, özel bir kenar ya da bant için dar dalga boyu aralığı gerektirmektedir. Bantın ya da kanalın spektral çözünürlüğü ne kadar yüksekse, o bant ya da kanalın dalga boyu aralığı o kadar dar demektir.

Spektrumun değişik bölgelerini kullanan çok bantlı görüntülere multispektral (MS) görüntüler adı verilir. Uzaktan algılama uydularının spektral çözünürlüğü, uydunun kaç bantta görüntü verebildiğine ve her bandın genişlik özelliğine göre belirlenir. Örneğin; LANDSAT MSS dört bantla veriler elde ederken, LANDSAT-TM yedi bantla aynı işlemleri gerçekleştirebilmektedir.



Şekil 2.10 Spektral çözünürlük kavramı (a) Pankromatik görüntü, (b) Multispektral görüntü.

Şekil 2.10a da verilen görüntüdeki pan bandı $0.51-0.73\mu m$ dalga boyu arasında olup, Şekil 2.10b de verilen görüntüdeki multispektral bant ise üç banttan oluşmaktadır. Band 2 mavi bant olup $0.52-0.60\mu m$, Band 3 Yeşil olup $0.63-0.69\mu m$ ve Band 4 kırmızı olup $0.75-0.90\mu m$ dalga boyu arasındadır.

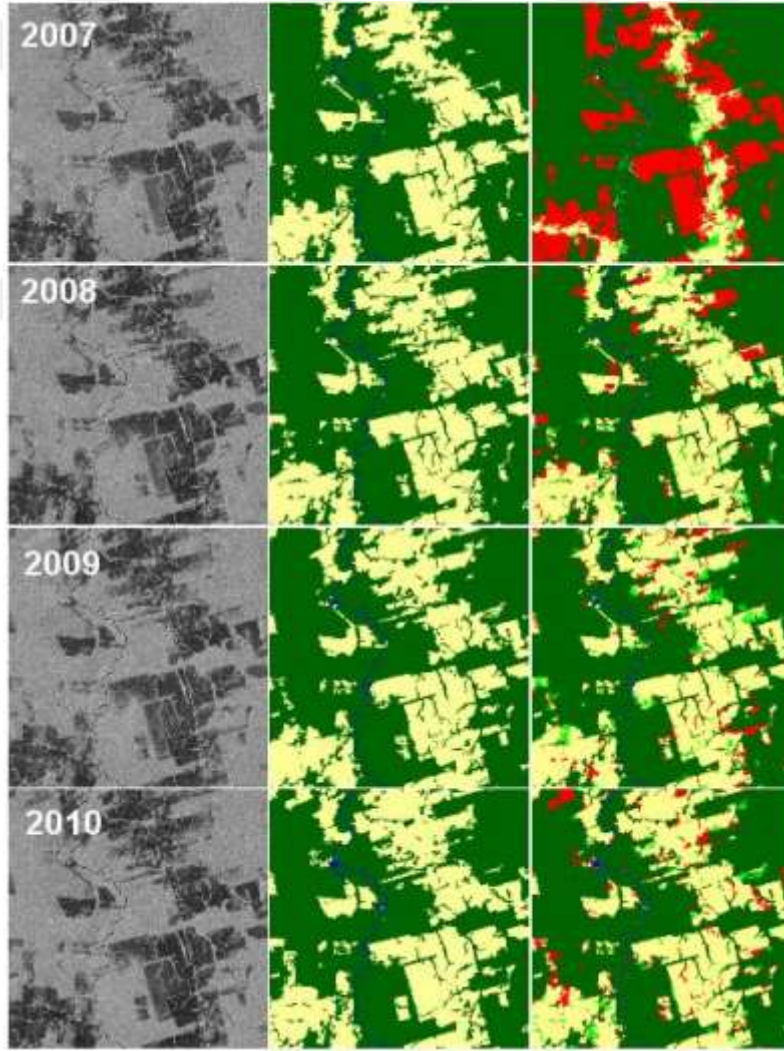


Şekil 2.11 Spot uydularının elektromanyetik spektrumunda algıladıkları bölgeler ve bant özellikleri.

2.5.4. Zamansal Çözünürlük

Zamansal çözünürlük, uydunun herhangi bir yere ait görüntü almasından itibaren, tekrar aynı görüntüyü alması arasındaki geçen süre olarak tanımlanmaktadır. Aynı görüntü tekrar alınırken uydunun hangi açıyla alındığı da önemlidir. Uzaktan algılamada çeşitli çalışmalar için zaman

içi deęişimler izlenmekte ve bunun için alıcının belirli bir noktayı ardışık olarak algılayacağı zaman dilimini ortaya koymaktadır (Şekil 2.12). Örneğin Spot uydusu 26 günde aynı noktadan geçerken LANDSAT-TM uydusu 16 günde, Advanced Very High Resolution Radrometer (NOAAA/AVHRR) uydusu ise günde 2 kez aynı noktadan geçmektedir). Uydular istenilen bölge için gerekli görülen zamanlarda geçemezler. Gerekli çalışmalar için bu sürelerin azaltılması istenebilir. Bu gibi durumlarda uydu, yalpa ya da yunuslama açısı verileri ile yörüngesini deęiştirilebilmektedir. Örneğin bir uydunun nadirden aldığı görüntüyü tekrar nadirden görüntüleyebilmesi için gerekli süre otuz gündür. +/- 30 derece yalpalama açısıyla aynı bölge iki ya da üç gün süreyle görüntülenebilmektedir. Literatürde zamansal çözünürlük için kullanılan farklı yönelim açılarıyla elde edilen bu süreler geçerli sayılmaktadır. Yani bu örnek için zamansal çözünürlük iki ya da üç olarak sayılmaktadır (Çölesen 2008).



Şekil 2.12 Yıllara ait bölgedeki ormanlık alanlardaki zamansal deęişimin izlenmesi.



BÖLÜM 3

UZAKTAN ALGILAMADA GÖRÜNTÜ SINIFLANDIRMA TEKNİKLERİ

Dijital görüntülerde her nesne, farklı spektral yansıma değerlerine sahip olmasından ve algılayıcı sistemin farklı geometrik, radyometrik ve spektral çözünürlüklere sahip olmalarından dolayı, farklı dijital sayı değerleriyle temsil edilirler.

Görüntüdeki sınıflandırma işleminin bütün amacı; farklı değerlere sahip piksellerden oluşan bu nesnelere; gerçek dünyadaki arazi sınıflarına ya da temalarına göre kategorize ederek anlamlı sayısal haritalar üretebilmektir. Sınıflandırma işleminin içeriği genel olarak aşağıdaki gibidir:

- 1- Çalışma alanı ile ilgili detaylı arazi çalışması yapılır. Çalışma sonucunda sınıflar belirlenir. Kontrol alanları seçilir, haritalar temin edilir.
- 2- Çalışılan bölgeye ait kullanılan uydu görüntüsünün sınıflandırmada en iyi yansıma değerini ortaya çıkartacak spektral bantlar seçilir.
- 3- Sınıflar belirlendikten sonra görüntü üzerinden eğitim ve sonrasında doğruluk analizleri için kontrol verileri oluşturulur.
- 4- Kullanılan sınıflandırma methodlarına göre uygulanacak uygun algoritmalar belirlenir.
- 5- Sınıflandırma sonuçlarının vektörleştirilmesi, haritalarla ve arazi çalışmasıyla karşılaştırılması ve doğruluk analizlerinin yapılmasıyla çalışma tamamlanmış olur.

Görüntü sınıflandırma yöntemleri piksel-tabanlı ve nesne-tabanlı olmak üzere ikiye ayrılmaktadır. Piksel-tabanlı sınıflandırma, tekil piksellerin gri değerlerine dayanarak sadece spektral bilgiyi kullanarak sınıflandırma sonucu elde etmektedir. Günümüzde kullanılan IKONOS, Quickbird, Geoeye gibi yüksek çözünürlüklü uydu görüntülerinden elde edilen zengin bilgi içeriği, piksel-tabanlı sınıflandırma ile istenilen doğruluğu karşılamamaktadır. Daha doğru ve olumlu sonuçların üretilebilmesi için ihtiyaçlar doğrultusunda nesne-tabanlı sınıflandırma yöntemine yönelim başlamıştır. Nesne-tabanlı sınıflandırma yaklaşımı piksel-tabanlı sınıflandırma yaklaşımından farklı olarak piksellerin sadece spektral bilgilerine

dayanarak değil yapısal, dokusal gibi ek bilgileri de kullanarak pozitif sonuçların elde edilmesini sağlamaktadır. Segmentasyon aşamasında kullanılan algoritmalarla; ölçek, şekil ve bütünlük gibi niteliklerin belirlenmesiyle de homojen görüntü nesnelere ortaya çıkmaktadır.

3.1. PİKSEL-TABANLI SINIFLANDIRMA YAKLAŞIMI

Piksel-tabanlı sınıflandırma arazi örtü tiplerini ve yapılarını piksel bazında değerlendiren; atanacak sınıf ile spektral benzerliği karşılaştıran sınıflandırma yöntemidir. Görüntüdeki bütün pikseller tek tek değerlendirilir ve ait oldukları sınıflara atanırlar.

Piksel-tabanlı sınıflandırma Kontrolsüz (Eğitimsiz) Sınıflandırma ve Kontrollü (Eğitilmiş) Sınıflandırma olmak üzere ikiye ayrılır. Bu konuyla ilgili detaylı bilgi aşağıdaki başlıklarda verilmiştir.

3.1.1. Kontrolsüz (Eğitimsiz) Sınıflandırma Yöntemi

Kontrolsüz sınıflandırma kontrol bölgeleri seçilmeden, piksellerin kullanıcı müdahalesi olmadan otomatik olarak kümelendirilmesi işlemidir. Önemli olan sınıflandırılacak arazi tiplerine ait dijital değerlerin birbirlerinden ayırt edilebilmesi için ölçme uzayında yakın konumda olmalarıdır. Bu şekilde birbirinden olumlu sonuçlarla ayrılmış doğal kümeler oluşmuş olur. Sınıflandırma yapabilmek için az sayıda örnek olması yeterlidir (Lillesand et al. 2007). Sınıflandırma sonucunda oluşacak sınıflar spektral sınıflardır. Bu spektral sınıflar, görüntüdeki doğal dijital değerlere bağlı olarak gruplandıklarından, sınıflandırmadan önce kullanıcı gruplarının ne olduğu hakkında bilgi sahibi olamayacaktır.

Kontrolsüz sınıflandırma yöntemleri içinde en sık kullanılan yöntem ISODATA'dır (Tekrarlı veri analizi yöntemi). Bu yöntem sınıflandırmayı tekrarlı olarak gerçekleştirir ve her iterasyon sonrasında yeniden hesaplanmasını temel alarak minimum girdi verisi ile kümelemeyi oluşturur. Karar kuralı olarak, minimum uzaklığı kullanır. Pikseller, görüntünün sol üst köşesinden başlanarak her satırda, soldan sağa analiz edilirler. Aday piksel ile her bir küme ortalaması arasında spektral uzaklık hesaplanarak en yakın kümeyle atanır. Kontrolsüz sınıflandırma; arazi örtüsü üzerindeki sınıf tiplerini bilmeye gerek olmadan sadece sınıf sayıları ile belirlenir. Ayrıca veri bantlarının değerleri kullanılarak benzer pikseller otomatik olarak

atanır. Bu sınıflandırma, görüntüden veri tanımlama işlemi yapılmadığında kullanılan bir yöntemdir (URL-1).

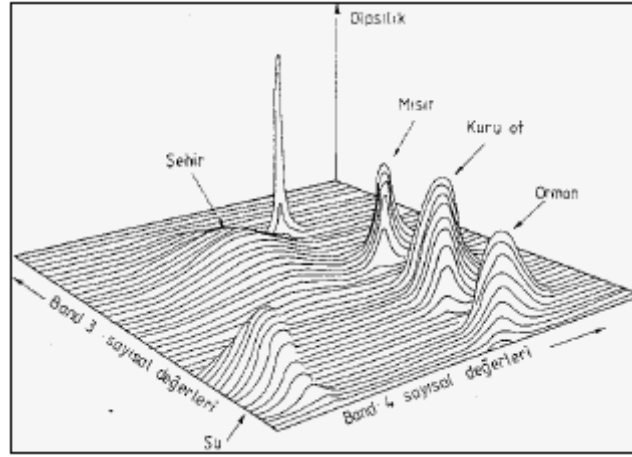
3.1.2. Kontrollü (Eğitilmiş) Sınıflandırma Yöntemi

Kontrollü sınıflandırma yönteminde; görüntüden çıkartılacak sınıflar önceden belirlendiği ya da bilindiği için, görüntüden ayırt edilebilecek bu sınıflara ait örnekleme alanları seçilir ve sınıflandırma doğruluğunu doğrudan etkileyen bir etmendir. Bu seçim yapılırken gerekli görülürse arazi çalışması da yapılmaktadır. Seçilen bu örnekleme alanları kullanılarak piksel değerlerini gösteren özellik dosyaları oluşturulur. Uygulamada, sonuçların analizi yapılırken karşılaşılan en büyük sorun birbirine yakın yansıma değerine sahip sınıfların çakışması durumudur. Bu çakışmanın nedeni; seçilen örnekleme alanlarının seçiminden ya da ölçümünden kaynaklanan hatalardır (URL-1). Bu hataları örnekleme alanlarının doğruluğu kontrol edilerek en aza indirebilecek yöntem ve algoritmalar bulunarak, atanan yanlış piksellerin sayısı azaltılabilmektedir.

Kontrollü sınıflandırma yöntemi kontrolsüz sınıflandırma yöntemine göre eğitim veri seti kullanıldığından daha olumlu sonuçlar vermekte ve en çok tercih edilen yöntem olmaktadır (Kavzaoğlu ve Çölkesen 2010). En çok kullanılan sınıflandırıcılar; maksimum benzerlik, minimum uzaklık ve paralelyüz yöntemleridir. Bu yöntemler istatistiksel kavramlar ve yapay sinir ağlarına dayalı yöntemlerdir (Ayhan vd. 2003). Çalışmada piksel-tabanlı sınıflandırma yöntemlerinden ‘Maksimum Benzerlik’ sınıflandırma yöntemi kullanıldığı için aşağıda sadece bu yöntem açıklanmıştır.

3.1.2.1. Maksimum Benzerlik Sınıflandırma Yöntemi

Maximum benzerlik yöntemi, kontrollü sınıflandırma yöntemleri içinde en çok bilinen ve kullanılan sınıflandırma yöntemidir. Bilinmeyen bir pikselin sınıflandırılması, sınıflandırılacak spektral sınıf setinin varyans ve kovaryans değerlerinin nicel olarak değerlendirilmesiyle yapılır. Bu değerlendirme yapılırken nokta kümelerinin normal dağılımda oldukları varsayılır. Çalışma alanına ait kullanılan uydu görüntüsünden toplanan eğitim alanları için ortalama kovaryans ve vektör matrisi hesaplanır. Böylece bilinmeyen herhangi bir pikselin belirlenen sınıflardan birinde olma olasılığı hesaplanmış olur.



Şekil 3.1 Olasılık yoğunluk fonksiyonları (Lillesand et al. 2007).

Şekil 3.1'deki olasılık değerleri üç boyutlu grafikte gösterilmiştir. Düşey eksen; herhangi bir pikselin, herhangi bir sınıfta olma olasılığını göstermektedir. Buradaki her bir yüzey olasılık fonksiyonu olarak tanımlanır ve her bir spektral sınıf için böyle bir fonksiyon da mevcuttur. Bu şekilde her bir pikselin her bir sınıfta olma olasılığı hesaplanmış olur. Bu işlemden sonra piksel en yüksek olasılık değerine sahip olduğu sınıfa atanır. Eğer bu değer, kullanıcının belirlediği eşik değerinin altında kalmış ise piksel 'bilinmeyen' olarak sınıflandırılır (Lillesand et al. 2007).

Bu yöntem Şekil 3.1'deki gibi, dağılım diyagramı üzerindeki elipsoidal eş olasılık konturlarını belirler. Konturların merkezine yaklaştıkça olasılık değeri artar. Bu yöntemin kovaryansa olan duyarlılığı, eş olasılık konturlarının şekline göre değişim göstermektedir.

Maximum benzerlik sınıflandırma yönteminde; herhangi bir pikselin, herhangi bir sınıfta olma olasılık fonksiyonu aşağıda belirtildiği gibidir.

$$P_i(x) = \frac{1}{(2\lambda)^{N_i/2} |V_i|^{1/2}} \exp\left[-\frac{1}{2}(X - \mu_i)^T V_i^{-1}(X - \mu_i)\right] \quad (3.1)$$

Bu eşitlikte;

N_i = Bant sayısı

μ_i = Ortalama değer

V_i = Kovaryans matrisi olarak tanımlanır (Zhiyuan 2004).

Bu yöntem, her pikselin hangi sınıfa ait olma olasılığını hesaplarken fazlaca matematiksel yöntem kullandığından diğer yöntemlere göre biraz daha yavaş çalışır. Ayrıca; yöntem görüntüdeki yapısal ve dokusal bilgiyi kullanmadan sadece spektral bilgiyi kullandığı için nesne-tabanlı yöntemlerine göre daha sınırlı sonuçlar üretmektedir (Zhou and Robson 2001, Dean and Smith 2003, Pizzolato and Haertel 2003).

3.2. NESNE-TABANLI SINIFLANDIRMA YAKLAŞIMI

Nesne-tabanlı sınıflandırma yaklaşımı, piksel-tabanlı sınıflandırma yaklaşımına göre sadece tekil piksellere göre değil görüntüdeki segmentler ve nesnelere de esas olarak sınıflandırma yapma esasına dayanmaktadır. Görüntü üzerinden gerçek dünya nesnelere göre sınıflandırma ve gerçek şekillerde olması nesne-tabanlı sınıflandırma yaklaşımına olumlu bir sonuç sağlamaktadır (Hofmann 2001a, b, c).

Sınıflandırma fikri, yüksek çözünürlüklü uydu görüntülerinin klasik, geleneksel sınıflandırma yöntemlerinde bulunmayan karakteristik yapısal ve dokusal bilgiye sahip olduklarından dolayı ortaya çıkmıştır (Blaschkes and Strobl 2001). Klasik piksel-tabanlı sınıflandırma yöntemleri her piksel için n boyutlu veri vektörünü, her sınıfın prototip vektörü ile kıyaslayarak, görüntüdeki her bir piksel sınıfını tanımlar. Veri vektörü piksellerin ya gri değerlerinden ya da hesaplanan yapısal, dokusal, içeriksel bilgilerinden oluşur. Bu içeriksel ve dokusal bilgiler, değerlerinin değişimleri hakkında bilgi almak için de kullanılır. Nesne-tabanlı sınıflandırma yaklaşımında kullanılan yöntemler direk olarak bireysel pikseller üzerinden sonuçlandırma yapamazlar. Bu yöntemler birçok pikselin oluşturduğu, görüntü üzerinden anlamlı sonuçlar çıkartabilecek çeşitli görüntü segmentasyonu oluşturarak çalışırlar. Görüntüdeki tekil pikseller yerine, bu piksellerin oluşturduğu nesnelere kullanılırlar (Carleer and Wolff 2006, Blaschke 2010). Bu nesnelere sınıflandırırken sadece piksel-tabanlı sınıflandırmada kullanılan spektral bilgiler değil, komşuluk ilişkileri ve şekil karakteristikleri de kullanılır (Shackelferd and Davis 2003).

Nesne-tabanlı sınıflandırmanın piksel-tabanlı sınıflandırmaya göre daha olumlu sonuçlar vermesinin bir nedeni olarak 'tuz-biber etkisi' de gösterilebilir. Bu etki piksel-tabanlı sınıflandırmada, sınıflandırma doğruluğunu azaltan ve piksellerin komşu piksellerden ayrı, bağımsız bir şekilde sınıflandırıldığında karşılaşılan; çalışmayı olumsuz etkileyen önemli bir etmdir. Sensör özellikleri değiştirilmeden sadece konumsal çözünürlük artırıldığında da

sınıflandırma doğruluğunda azalma olduğu görülmektedir. Başka bir sorun olarak, farklı fiziksel özelliklere sahip küçük parçaların mozaik oluşturduğu alanlarda da yine olumlu sonuçlar alınamamaktadır. Bütün bu olumsuzlukları ve sorunları aşabilmek için de çoğunlukla nesne-tabanlı sınıflandırma yöntemleri kullanılmaktadır (Mathiev et al. 2007).

Nesne-tabanlı sınıflandırma yaklaşımında, her sınıflandırma işlemi ölçeğin farklılığına bağlı olarak farklı sonuçlar vermektedir. Görüntüden alınacak bilgi, görüntüdeki nesnelerin büyüklüğüne göre farklı ölçekler kullanılarak da çıkartılabilir. Görüntüdeki bu nesneler ölçek etkenine bağlı olarak daha küçük ya da daha büyük objelere ayrılmış olarak segmentasyonları yapılabilmektedir. Görüntüden alınacak doğru ve hassasiyetli bilgiye göre eş zamanlı olarak farklı ölçek bilgileriyle sunmayı da mümkün kılmıştır. Ayrıca nesne tabakaları birbirleriyle ilişkilendirilerek de çalışmaya fayda sağlayacak ek bilgilerin çıkarımına da katkıda bulunmaktadır. Hiyerarşik ağ düzenlerini örnek alırsak, komşu nesnelerin yanında düzenli bir hiyerarşik yapıya sahip nesneler, alt ve üst nesnelere de tanımlamayı sağlayabilmektedir. Bu da, alt nesnelerin yüksek doğruluklu analizlerinin yapılmasını sağlamakla birlikte, bu hiyerarşik yapı olmadan böyle bir hassasiyete ulaşmak mümkün olmamaktadır. Bu bilgiye bağlı olarak alt nesnelerin yapısından faydalanarak üst nesnelerin şekilleriyle ilgili bilgilerde değişiklik yapılabilmektedir (Marangoz vd. 2004).

Sınıflandırma analizinde nesneler üzerinden şekil, doku, komşuluk ve diğer tabakları kullanarak daha birçok ek bilgi çıkartabilmektedir. Bu bilgiler sınıflandırma doğruluğunun artmasını direk olarak da etkilemektedir. Baatz vd. (2005), sınıflandırmada kavramsal bakış açısıyla olabilecek özellikleri aşağıdaki gruplandırmıştır:

Temel özellikler: Objelerin fiziksel özellikleri; gerçek dünyaya bağlantı kurulmadan sensör ve aydınlatma durumuyla belirlenir. Bu özellikler de renk, doku ve nesne yapılarını ifade eder.

Topolojik özellikler: Geometrik komşuluğu ifade eder. Görüntüdeki nesnelerin, birbirleriyle olan konumsal ilişkilerini kullanan bir özelliktir. Örneğin; bir nesnenin bir nesneden ne kadar mesafe uzaklıkta olduğu ya da sağında, solunda olma durumunu ifade eder.

Çevresel özellikler: Semantik komşuluk ilişkilerini ifade eden özelliklerdir. Örneğin, görüntüden seçilen bir evin etrafının tamamen yeşil alanla çevrili olmasını ifade eder.

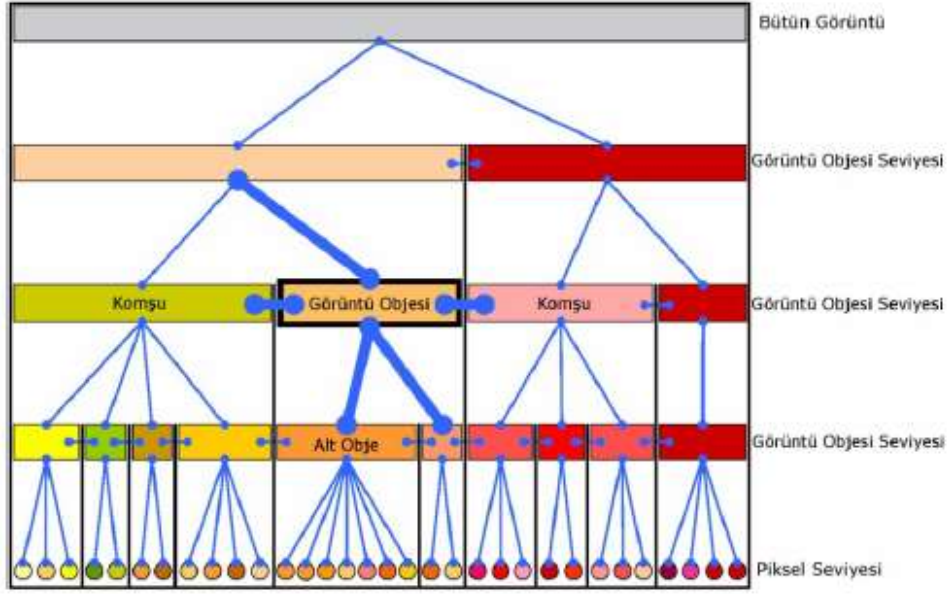
Nesne-tabanlı sınıflandırma sırasıyla segmentasyon ve sınıflandırma olmak üzere iki işlem adımıyla gerçekleşir. Aşağıdaki bölümlerde bu adımlar detaylı bir şekilde anlatılacaktır.

3.2.1. Segmentasyon

Nesne-tabanlı sınıflandırma yaklaşımının ilk adımı segmentasyondur. Segmentasyon sınıflandırma başarısını doğrudan etkileyen bir etmendir. Doğru parametre değerleri kullanılarak yapılan nesne-tabanlı sınıflandırma her zaman piksel-tabanlı sınıflandırmaya göre daha doğru sonuçlar verir (Yan et al. 2006). Amaç görüntüden gerçek dünya şekillerine benzeyen nesnelere çıkartabilmektir. Bu işlem ile segmentlerdeki heterojenlik en az seviyeye indirilmiş olur ve görüntüden alınacak bilgi artık piksel bazında değil nesne bazında olacaktır. Bu şekilde, milyonlarca pikselle uğraşmak yerine, homojen spektral özelliğe sahip istenilen uygunlukta nesnelere oluşturularak daha doğru bir sınıflandırma yapılmış olur. Segmentasyon bu aşamada sınıflandırmaya büyük bir avantaj sağlamaktadır.

Görüntü segmentasyonunda istenilen, çalışma kapsamında analiz edilecek nesnelere otomatik çıkarımlarının yapılabilmesidir. Böyle bir durumda başvurulan ilk durum özelleştirilmiş algoritmaların kullanılmasıdır. Bazıları yarı otomatik bazıları da tam otomatiktir. Bu geliştirilen algoritmaların kendilerine özgü avantaj ve dezavantajları vardır.

Bu çalışmada kullanılan eCognition yazılımı kullanıcılara 7 farklı segmentasyon algoritması sunmaktadır. Bu algoritmalar iki ana prensibe göre segmentasyon yapabilirler. Ortaya çıkartılacak sonuç ürünlerin, nesnelere çok ölçekli sonuçları göz önüne alındığında küçük nesnelere, daha büyük anlamsal hiyerarşiyi oluşturan nesnelere oluşturmak için birleştirilebilirler. Aynı şekilde büyük nesnelere de küçük nesnelere bu yaklaşımla bölünebilirler (Şekil 3.2). Bu iki yaklaşım yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) olmak üzere gruplandırılmıştır (Trimble 2012).




Şekil 3.2 Yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) yaklaşımı.

3.2.1.1. Yukarıdan Aşağıya (Top-Down) Stratejisi

Yukarıdan aşağıya stratejisinde; objelerin büyük parçalardan daha küçük parçalara bölünmesi esas alınır. Burada görüntü tek bir büyük obje olarak düşünülebilir. eCognition yazılımında bu yaklaşım için 4 farklı segmentasyon algoritması bulunmaktadır. Bunlar; Chessboard, Quadtree-Based, Contrast Filter ve Contrast Split segmentasyon algoritmalarıdır.


Chessboard Segmentasyonu; yazılımın en basit algoritmasıdır. Görüntünün, istenilen ve eşit boyutlardaki karelere bölünerek görüntü objelerine ayırmak için kullanılır (Şekil 3.3). Spektral bir değer kullanılmamakta olup, sadece kullanıcı tarafından belirlenen alansal büyüklük tanımlaması ile yapılmaktadır.



Şekil 3.3 Grid segmentasyonu.

Quadtree-Based Segmentasyonu; chessboard segmentasyonu ile hemen hemen benzerlik gösterir. Farklı olarak kullanıcının belirlediği renk tonu farklılıkları eşik değerine göre değişen büyüklüklerde ve homojen nesnelere oluşturan dörtlü karelerden oluşmaktadır (Şekil 3.4).

Algoritma kullanıcının istediği homojenliğe ulaşana kadar fonksiyonu tekrarlamaktadır. Kısacası homojenliğin sağlanmadığı bölgelerde her bir kare, dört kareye daha bölünerek homojenlik sağlanana kadar devam eder. Homojen bölgelerdeki kareler, heterojen bölgelere göre daha büyüktür.



Şekil 3.4 Dörtlü ağaç yapısı segmentasyonu.

Contrast Filter Segmentasyonu; iki görüntü katmanı ya da banttaki piksel değerlerine ait kontrast ve değişim derecelerinin (gradient), kullanıcının belirlediği eşik değerlerinin kullanılmasıyla görüntü nesnelere oluşturulmaktadır. Chessboard segmentasyonu ile benzer olarak kullanıcının belirlediği boyutlarda karelere bölünmektedir. Ardından tanımlanan sınıfların eşik değerleri belirlenmekte ve görüntü nesnelere sınıflandırılmaktadır. Bu algoritma genellikle pirimitif başka bir deyişle basit görüntü nesnelere oluşturulmasında kullanılır ve sınıflandırma tek bir adımda gerçekleşir.

Contrast Split Segmentasyonunda; görüntü kullanıcının belirlediği eşik değerleri doğrultusunda koyu ve parlak görüntü nesnelere ayrılır. Chessboard segmentasyon algoritması bu algoritma içinde kullanılır ve orada olduğu gibi görüntü eşit boyutlardaki karelere ayrılır. Sonrasında, belirlenen eşik değerleri doğrultusunda görüntü sınıflandırması gerçekleştirilir.

3.2.1.2. Aşağıdan Yukarı (Bottom-Up) Stratejisi

Küçük objelerin birleşerek daha büyük objeleri oluşturduğu aşağıdan yukarı (bottom-up) stratejisinde amaç daha önceden oluşturulan görüntü nesnelere veya görüntü piksel seviyesinden daha homojen ve büyük nesnelere oluşturmaktır. eCognition yazılımında bu strateji için 3 farklı algoritma bulunmaktadır. Bunlar, Multi-Resolution, Multi-Threshold ve Spectral Difference Segmentasyon algoritmalarıdır.

Multi-resolution segmentasyon algoritması; kullanıcının belirlediği spektral (color) ve şekilsel heterojenite (smoothness ve compactness) kriterleri doğrultusunda, pikseller ve daha önceden oluşturulmuş görüntü nesnelere oluşturur. Uygulamalarda en çok tercih edilen algoritmadır. Sınıflandırma ve görüntü işlemleri için başlangıç nesnelere üretir (Baatz and Schape 2000). Bu algoritmada homojen alanlar büyük nesnelere içlerinde, heterojen alanlar ise daha küçük nesnelere içinde sonuçlar verir.

Multi-Resolution Segmentasyonu bir alan birleştirme tekniğidir. Küçük piksellerin büyük piksel grupları içinde birleşmesini sağlar (Benz et al. 2004). Düzensiz çözünürlükteki farklı veri türlerinden yüksek homojen nesnelere oluşumunu da sağlamaktadır (Baatz and Schape 2000).

Bu aşamada obje birleşim değeri “ f ” spektral homojenite “ h_{color} ” ve şekilsel heterojenite “ h_{shape} ” için aşağıdaki şekilde hesaplanmaktadır. “ w ” kullanıcı tarafından tanımlanan şekil ve renk ağırlıklarıdır.

$$f = w \cdot h_{color} + (1 - w)h_{shape} \quad (3.2)$$

Spektral homojenite “ h_{color} ” aşağıda gösterildiği gibi bulunmaktadır. Denklemdaki “ w_c ” kullanılan verideki her bir spektral bant için kullanıcı tarafından belirlenen ağırlık katsayısı, “ σ ” banttaki spektral değerlerin standart sapmasını ve “ n_i ” ise görüntü nesnesindeki piksel sayısını ifade etmektedir.

$$h_{color} = \sum_c w_c (n_{Merge} \cdot \sigma_c^{Merge} - (n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2})) \quad (3.3)$$

Şekilsel heterojenite “ h_{shape} ” aşağıdaki şekilde belirlenmektedir. “ w_{cmpct} ” kullanıcı tarafından verilen kompaktlık katsayısı, “ h_{cmpct} ” ve “ h_{smooth} ” ise görüntü objesi üzerinden hesaplanan kompaktlık (Compactness) ve pürüzsüzlük (Smoothness) değerleridir.

$$h_{shape} = w_{cmpct} \cdot h_{cmpct} + (1 - w_{cmpct}) \cdot h_{smooth} \quad (3.4)$$

h_{cmpct} Kompaktlık (Compactness) ve “ h_{smooth} ” pürüzsüzlük (Smoothness) değerleri ise aşağıdaki şekilde hesaplanmaktadır. “ l_i ” objenin fiili sınır uzunluğu yani çevresi ve “ b_i ” ise olası en büyük sınır çevresidir.

$$h_{cmpct} = n_{Merge} \cdot \frac{l_{Merge}}{\sqrt{n_{Merge}}} - (n_{obj1} \cdot \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} \cdot \frac{l_{obj2}}{\sqrt{n_{obj2}}}) \quad (3.5)$$

$$h_{smooth} = n_{Merge} \cdot \frac{l_{Merge}}{b_{Merge}} - (n_{obj1} \cdot \frac{l_{obj1}}{b_{obj1}} + n_{obj2} \cdot \frac{l_{obj2}}{b_{obj2}}) \quad (3.6)$$

Yapılan literatür çalışması sonucunda en uygun sonuçların bu algoritmanın kullanımı sonucunda oluşturulan görüntü nesnelere üzerinden alındığı saptanmıştır (Baatz and Schäpe 2000, Benz et al. 2004, Blaschke 2010, Blaschke et al. 2014, Bock et al. 2005, Burnett and Blaschke 2003, Corbane et al. 2008). Bu çalışmada, segmentasyon aşamasının sunduğu avantajlardan dolayı Multi-Resolution Segmentasyon algoritması kullanılmıştır.

Multi-Threshold Segmentasyon algoritması; kullanıcının belirlediği eşik değerleri ile görüntü nesnelere oluşturur ve sonrasında algoritmada tanımlanan eşik değerleri doğrultusunda oluşturulan görüntü nesnelere üzerinden sınıflandırma yapar. Görüntü objelere multi-resolution segmentasyon algoritması ile oluşturulurken, sınıflandırmalar histogram tabanlı yapılan tanımlamalar ile yapılmaktadır. Görüntü objelere oluşturulurken tek bir bant üzerinden segmentasyon yapılabilmektedir.

Spectral Difference Segmentasyon algoritması; daha önceden görüntüden oluşturulmuş spektral değerleri birbirine yakın nesnelere birleştirir. Önceden yapılan segmentasyon sonuçlarının iyileştirilmesinde kullanılır. Direk olarak pikseller üzerinden kullanımı mümkün değildir.

3.2.2. Segmentasyon Parametreleri

Segmentasyon algoritması, homojenik kavramı ile doğru orantılıdır. Görüntü nesnesinin doğru çıkarımını yapabilmek için ölçek, şekil ve bütünlük kriterlerinin amaca uygun tanımlanması


gerekmektedir. Bu aşamada seçilen segmentasyon parametreleri görüntü nesnelерinin boyut, şekil ve sahip oldukları homojenliği direkt etkilemektedir. Ölçek parametresiyle birlikte şekil ve bütünlük parametrelerinin dahil edilmesi çoklu çözünürlüklü segmentasyon ile yapılmaktadır. Bu parametreler kullanıcı tarafından belirlenmiş olup, en iyi sonucu alana kadar deneme yanılma yoluyla belirlenmektedir. Segmentasyon sonucu nicel olarak iyi değerlere sahip olsa bile, kullanıcıyı yeterince tatmin etmediği sürece anlamlı değildir. Bu parametrelerin yanı sıra her bir görüntü bantına farklı ağırlık verilmesi de ufak değişiklikleri meydana getirmektedir (eCognition 2011b).

Bu tez çalışmasında segmentasyon parametreleri olan ölçek, şekil ve bütünlük parametreleri farklı değerlerle denenmiş olup, en uygun parametre değerleri belirlenerek uygulama yapılmıştır. Aşağıda bu 3 parametreyle ilgili detaylı bilgi verilmiştir.

3.2.2.1. Ölçek Parametresi

Ölçek parametresi, görüntü nesnelерinde oluşacak maksimum heterojeniteyi belirleyen bir kavramdır. Seçilen ölçek parametresi homojen verilere nazaran, heterojen verilerin daha küçük nesne boyutlarında oluşmasını sağlamaktadır. Ölçek parametresinin değişmesi oluşacak görüntü nesnesinin boyutunu doğrudan etkilemektedir. Parametre değeri ne kadar büyük seçilirse, nesne boyutu da o kadar büyük olacaktır. Bu büyüklük çalışmayı olumsuz da etkileyebilir. Büyük seçilen parametre ile bazı nesne türleri birbirinden ayrılmadan, tek bir nesne olarak oluşturulmalarına da neden olabilmektedir (Benz et al. 2004).

Sınıflandırmanın esası ölçek parametresine bağlıdır. Farklı ölçek parametreleri kullanılarak oluşturulan görüntü nesneleri istenilen boyutlarda elde edilerek, görüntü bilgisi de amaca uygun hale getirilmiş olmaktadır (Marangoz 2009). Farklı ölçekler kullanarak oluşturulan bir görüntü de, farklı nesne hiyerarşileri ile de sınıflandırma yapmak mümkündür (Şekil 3.5). Nesne hiyerarşisi, farklı nesne seviyelerini kullanarak ve eş zamanlı olarak farklı ölçeklerde gösterilebilir. Bu da farklı boyutlara sahip nesnelерin birlikte kullanımını sağlar (Oruç vd. 2007).



Şekil 3.5 Geoeye-1 uydu görüntüsünden alınmış 3 farklı ölçek parametresi (a- 50 küçük ölçek, b- 100 orta ölçek, c-200 büyük ölçek).

Benz et al. (2004)'e göre büyük, orta ve hassas ölçeklerle alınmış yerleşim alanından seçilen aynı yere ait segmentasyon aşaması aşağıdaki gibi yorumlanmıştır.

- Küçük ölçekler seçilirse; ağaçlar, binalar ve yollar ayrı ayrı gösterilir.
- Orta ölçekler seçilirse; ağaç ve bina grupları birleşme gösterir.
- Büyük ölçeklerde hassaslık unsuru yitirilir. Ormanlık alan, kentsel alan ve açık arazi bir nesne içinde gösterilir. Bu ölçekler büyüdükçe birbirlerini oluştururlar. Ev, yol, bina ve diğer kentsel alan özelliğini taşıyan nesnelere bir araya gelerek yerleşim alanını oluşturur. Farklı yerleşim alanlarının birleşmesiyle de şehirler meydana gelmiştir.

Ölçek parametresi kadar homojenlik kriterinin de görüntü nesnelere oluşturulmasında önemi büyüktür. Homojenlik kriteri spektral ve şekil unsurlarından oluşur. Rengi ve şekli belirten bu iki kriter heterojenliği belirler. Spektral yani renk kriteri anlamlı nesnelere oluşumu için önemli bir ölçütken; şekil kriteri ise nesnelere sınırlarının bütünlüğü ve yumuşaklığı arasındaki dengeyi korumaktadır. Bütünlük ve yumuşaklık kriterlerinin toplamı aynı zamanda heterojenlik parametre değerini vermektedir. Nesnelere homojenlik kriteri bu parametrelerin ağırlıklandırılması ile belirlenmektedir.

Benz et al. (2004); aşağıdaki denklemde verilen ağırlık parametrelerinin (w_{renk} , $w_{şekil}$) uygulamada heterojenlik tanımı uyumuna izin verdiğini söylemektedir. Denklemdeki birleştirme faktörü (f), spektral heterojenlik (Δh_{renk}) ve şekilsel heterojenlik ($\Delta h_{şekil}$) bileşenlerini içerir.

$$f = w_{renk} \cdot \Delta h_{renk} + w_{\text{şekil}} \cdot \Delta h_{\text{şekil}} \quad , \quad w_{renk} \ \& \ w_{\text{şekil}} \in [0,1] \quad (3.7)$$

$$w_{renk} + w_{\text{şekil}} = 1 \quad (3.8)$$

Aşağıdaki eşitlikte birleştirme parametresinin spektral (renk) bileşeni gösterilmiştir. Spektral heterojenlik; nesnenin spektral değerleri üzerinden yapılır ve bu piksellerin ağırlıklandırılmış spektral değerlerinin standart sapması ile orantılıdır. Burada n_{nesne_1} birleştirme için seçilen nesne, n_{nesne_2} komşu nesne, $n_{birleşim}$ ise n_{nesne_1} ve n_{nesne_2} nin birleşim sonucunu gösterir. Eşitlikte c spektral bant indeksi ve w_c kullanıcı tarafından seçilen bant ağırlığıdır. σ_c , nesnenin ait olduğu tüm piksellerin hesaplandığı c için piksel değerlerinin standart sapması ve n her nesnenin piksel sayısını ifade etmektedir.

$$\Delta h_{renk} = \sum_c w_c (n_{birleşim} \cdot \sigma_c^{birleşim} (n_{nesne_2} \cdot \sigma_c^{nesne_2})) \quad (3.9)$$

Eşitlik 3.3 birleşim faktörünün şekilsel bileşeni olan şekil parametresi, bütünlük ($\Delta h_{bütünlük}$) ve yumuşaklık ($\Delta h_{yumuşaklık}$) bileşenlerinden oluşur. Şekilsel heterojenlik yumuşak ve bütün nesne şeklinin sapmasını temel alır. Her bileşenin önemliliği $w_{bütünlük}$ ağırlığı ile ayarlanır. Bütünlük parametresi nesnenin çevre uzunluğu oranı ve alanın karekökü ile tanımlanır. Yumuşaklık parametresi nesne çevresinin oranı ve onun sınırlayıcı kutusunun uzunluğu olarak tanımlanır.

$$\Delta h_{\text{şekil}} = w_{bütünlük} \cdot \Delta h_{bütünlük} + w_{yumuşaklık} \cdot \Delta h_{yumuşaklık} \quad (3.10)$$

Eşitlik 3.4 ve 3.5’de bütünlük ($\Delta h_{bütünlük}$) ve yumuşaklık ($\Delta h_{yumuşaklık}$) bileşenleri gösterilmiştir. Burada n ile nesne büyüklüğü, l ile nesnenin çevre uzunluğu, b ile sınırlayan kutunun çevre uzunluğu ifade edilmektedir. Yumuşaklık ve bütünlük parametrelerinin toplamı 1 değerine eşittir.

$$\Delta h_{\text{bütünlük}} = n_{\text{birleşim}} \frac{l_{\text{birleşim}}}{\sqrt{n_{\text{birleşim}}}} - \left(n_{\text{nesne}_1} \frac{l_{\text{nesne}_1}}{\sqrt{n_{\text{nesne}_1}}} + n_{\text{nesne}_2} \frac{l_{\text{nesne}_2}}{\sqrt{n_{\text{nesne}_2}}} \right) \quad (3.11)$$

$$\Delta h_{\text{yumuşaklık}} = n_{\text{birleşim}} \frac{l_{\text{birleşim}}}{b_{\text{birleşim}}} - \left(n_{\text{nesne}_1} \frac{l_{\text{nesne}_1}}{b_{\text{nesne}_1}} + n_{\text{nesne}_2} \frac{l_{\text{nesne}_2}}{b_{\text{nesne}_2}} \right) \quad (3.12)$$

Yukarıda verilen eşitliklerdeki değerlerin, heterojenliğin ayarlanabilmesi ve nesnelerin tanımlanabilmesi için kullanılmaları gerekmektedir. Heterojenliğin ayarlanması; spektral bant ağırlığı, bütünlük ağırlığı ve renk ağırlığının oluşturduğu segmentasyon parametre değerlerinin belirlenmesi ile yapılmaktadır (Feitosa et al. 2006).

3.2.2.2. Şekil Parametresi

Şekil parametresi, oluşturulacak nesnelerin renk ve şekil kriterleri arasındaki ilişkiyi düzenler. Aralarındaki ilişki ters orantılı olarak da yorumlanabilmektedir. Şekil kriterinin değiştirilmesi, renk kriteri değerinin değişmesine neden olmaktadır. Parametre 0 ile 1 arasında bir değer almaktadır. Şekil ve renk kriterinin toplamı 1 değerine eşittir. Şekil kriteri 0.3 iken renk kriteri 0.7 değerini almaktadır. Bu değer kullanıcı tarafından görüntüden çıkartılacak nesnenin homojenliğine bağlı olarak belirlenir. Şekil homojenliğinin derecesi, nesnenin kalitesini doğrudan etkilemektedir. Yüksek çözünürlüklü uydu görüntülerinin kullanımında fazla parçalanmış görüntü nesnesi oluşumunu engellemek için de kullanılmaktadır. Şekil parametresinin 0-1 aralığındaki değer skalasında 1 değerine yaklaştıkça segmentasyon kalitesi azalmaktadır (eCognition 2011 a).

3.2.2.3. Bütünlük Parametresi

Nesnelerin bütünlüğüyle ilgili tanımlamayı yapan parametredir. Daha bütün ve daha yumuşak nesnelerin oluşumunu sağlar. Parametre 0 ile 1 arasında değer alır. Bu değer kullanıcı tarafından diğer parametrelerin uyumu ile de karşılaştırılarak belirlenir. Yumuşaklık ve bütünlük parametreleri birlikte ilişkilendirilir. Bu iki parametre değerinin toplamı 1 değerine eşittir. Bütünlük parametresi 0.4 seçildiğinde yumuşaklık parametresi 0.6 değerine karşılık gelmektedir (eCognition 2011a).

3.2.3. Sınıflandırma Aşaması

Segmentasyon işlemi ile görüntüden homojen, anlamlı nesnelere çıkartılır. Bu aşamadan sonra sınıflandırılacak veri artık piksel değil bu nesnelere dir. Sınıflandırma aşamasında, kullanıcı görüntüden segmentasyon sonucu oluşan nesnelere sınıflara ataması gerekmektedir. Kullanıcı sınıflandırma yaparken, piksellerin sadece spektral değerlerini değil şekil, doku, içerik ve bunlarla birlikte semantik bilgilerini de göz önünde bulundurarak yapar.

eCognition yazılımı kullanıcılara 2 farklı sınıflandırma yöntemi sunar. Bunlardan ilki oluşturulan segmentlerin üzerinden belirlenen sınıflara ait örnekler alınarak yapılan en yakın komşuluk (nearest neighbour) sınıflandırma yöntemidir. Bu yöntem piksel-tabanlı sınıflandırmadaki kontrollü sınıflandırmaya benzer. Oluşturulan segmentler üzerinden sınıflara ait örnek segmentler seçilir. Sınıflandırmada tek tek pikseller üzerinden değil de, segmentler üzerinden örnekleme alanları seçildiği için daha hızlı çalışmakta ve daha doğru sonuçlar vermektedir (Jensen 2005). Seçilen örneklerin ortalama değerleri alınarak eCognition yazılımındaki en yakın komşuluk yöntemiyle görüntüdeki aynı özelliklere sahip segmentler bulunarak sınıflandırma işlemi tamamlanır.

Yazılımda kullanılan ikinci sınıflandırma yöntemi karar seti dosyası oluşturularak yapılan yöntemdir. Burada tematik sınıflar için bu sınıflara ait kullanıcının belirlediği eşik değerlerine ve sınıflara ait özelliklere göre sınıflandırma yapılır. Sınıfların her biri için hangi segmentasyon parametrelerinin kullanılacağı, hangi bantın hangi aralığının kullanılacağı, hangi dokusal ve alansal özelliklerin belirtilerek sınıflandırma yapılacağı gibi ve daha birçok istenilen özellik dahil edilerek yapılan yöntemdir. Diğer yöntemlere göre farkı, kullanıcı tarafından örnek alanlar seçilmezken yine kullanıcının belirlediği, her aşamasında yeniden parametrelerin belirlenebildiği, eklenebildiği daha güncel ve esnek bir karar seti oluşturularak nesne çıkarımları için eşik değerlerinin de kullanıldığı bir sınıflandırma olmasıdır. Kullanıcı algoritmalarını kendi tanımladığı içinde oluşan segmentlerin özellikleri hakkında bilgi çıkarımını rahatlıkla yapabilmektedir (Kalkan 2011). eCognition yazılımı burada spektral yansıma değerlerinin yanı sıra nesnelere alan, uzunluk, komşuluk ve çizgisellik gibi özelliklerini de kullanabilmiş olmaktadır.

3.2.4. Sınıflandırma Doğruluğu

Sınıflandırmanın son işlem adımı doğruluk analizidir. Bu analiz için yapılacak araştırma, sınıflandırma sonucunda elde edilen verinin gerçek dünya nesnelere temsil eden baz alınacak bir veri ile karşılaştırarak aralarındaki doğruluğun belirlenmesini kapsar. Bu veri, çalışma alanının belirli noktalarından alınacak örnekler için arazi çalışması, tematik haritalar, hava fotoğrafları ya da yüksek çözünürlüklü uydu görüntüleri olabilir. Bu şekilde sınıflandırma sonucunda elde edilen nesnelere gerçek dünyadaki nesnelere ne kadar temsil ettiği yüzdelik olarak belirlenebilir.

Sınıflandırma doğruluğunun belirlenmesinde kullanılan en yaygın yöntem, sınıflandırmanın hata matrisinin oluşturulmasıdır. Hata matrisleri çalışmada kullanılan veri ile buna karşılık gelen sınıflandırma sonuçlarını birbirleriyle karşılaştırmaktadır. Bu şekilde piksellerin doğruluk değerleri yüzdelik olarak hesaplanabilir. Hata matrisinin ana köşegeni referans verinin yer örtüsüyle karşılaştırma sonucunun ne kadar başarılı sınıflandırıldığını gösterir. Ana köşegen üzerinde olmayan matris elemanları da bilinmeyen, ihmal edilen ya da dahil edilmeme hatalarını kapsamaktadır (Boyacı 2012). İhmal hataları köşegende yer almayan sütunları temsil ederken, dahil etme hataları da yer almayan satır elemanlarını temsil eder (Çizelge 3.1).

Çizelge 3.1 Sınıflandırma hata matrisi.

		Referans Veri				Satır Toplamı
		Sınıf 1	Sınıf 2	...	Sınıf N	
Sınıflandırılmış Veri	Sınıf 1	a_{11}	a_{12}		a_{1N}	$\sum_{k=1}^N a_{1k}$
	Sınıf 2	a_{21}	a_{22}		a_{2N}	$\sum_{k=1}^N a_{2k}$
	...					
	Sınıf N	a_{N1}	a_{N2}		a_{NN}	$\sum_{k=1}^N a_{Nk}$
	Sütun Toplamı	$\sum_{k=1}^N a_{k1}$	$\sum_{k=1}^N a_{k2}$		$\sum_{k=1}^N a_{kN}$	

Hata matrisi ile birçok hata ölçütü de elde edilebilir. Bunlardan en çok kullanılanlar; kullanıcı doğruluğu (KD), üretici doğruluğu (ÜD) ve genel doğruluk (GD)'tur (Yan 2003).

Kullanıcı Doğruluğu (KD)-(User Accuracy -UA), herhangi bir sınıfa atanan pikselin, gerçekte ne kadar o sınıfa ait olduğunu gösterir. Her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesnelerin sayısının, o sınıf içinde sınıflandırılan toplam piksel veya nesne sayısına (sattır toplamına) bölümü ile hesaplanır.

$$UA = \frac{a_{ii}}{\sum_{i=1}^N a_{ik}} \quad (3.13)$$

Üretici Doğruluğu (ÜD)- (Producer Accuracy- PA), piksel veya nesnenin gerçek değerinde sınıflandırma yüzdeliğini gösteren değerdir. Her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesne sayısının, o sınıf için seçilmiş gerçek yeryüzü tipi örnekleme sayısı toplamına (sütun toplamı) bölümü ile hesaplanır.

$$PA = \frac{a_{ii}}{\sum_{i=1}^N a_{ki}} \quad (3.14)$$

Hesaplanan bu iki doğruluk değeri birbirlerine ne kadar ve 100'e yakın ise sınıflandırma doğruluğu o kadar iyi sayılacaktır. Ama bu iki değerden biri 100'e yakın diğeri çok düşük bir değerde ise sınıflandırma yapılırken seçilen örnek alanların veya algoritmaların yeniden seçilerek yapılması gerekebilir.

Genel Doğruluk (GD)- (Overall Accuracy-OA), her bir sınıf için doğru olarak sınıflandırılmış piksel ya da nesne sayısının, toplam referans piksel sayısına bölünmesiyle hesaplanır. Kullanıcı ve üretici doğruluğunun ardından genel bir değerlendirme yapılmış olur.

$$OA = \frac{\sum_{k=1}^N a_{kk}}{\sum_{i,k=1}^N a_{ik}} = \frac{1}{n} \sum_{k=1}^N a_{kk} \quad (3.15)$$

Kappa Değeri (k), hata matrisinin sattır ve sütun elemanlarının toplamı ile ana köşegen üzerindeki elemanlar kullanılarak hesaplanır. Kappa değeri 0 ile 1 arasında bir değer alır.

Değerin 1'e yakınlığı yapılan sınıflandırmanın doğruluğuyla doğru orantılıdır (Lillesand et al. 2007).

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})} \quad (3.16)$$

Yukarıdaki eşitlikte;

r = hata matrisindeki toplam satır sayısı,

x_{ii} =i. satır ve sütundaki piksel sayısı,

x_{i+} =i. satırdaki toplam piksel sayısı,

x_{+i} =i. sütundaki toplam piksel sayısı,

N = matrisin tamamındaki piksel sayısı olarak tanımlanır.

Hata matrisi ve kappa istatistiğinin hesaplanma yöntemleri birbirlerinden farklı olduğu için sonuçları da farklı olacaktır. İkisi arasındaki doğru olan sonuç kappa istatistiği sonucunun hata matrisinin sonucundan küçük olacak olmasıdır.

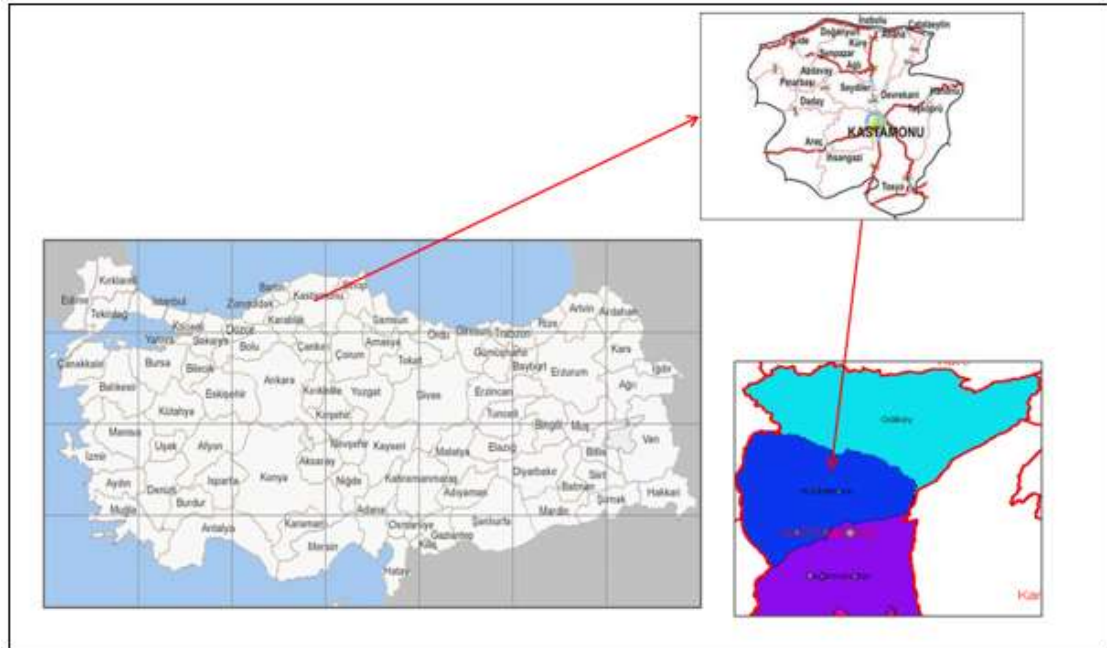


BÖLÜM 4

UYGULAMA

4.1. ÇALIŞMA ALANI

Orman ağaçlarının yoğun olarak bulunduğu 24 320 ha büyüklüğündeki 41°18.253' ve 41°28.974' kuzey enlemleri ile 33°32.742' ve 33°47.24' doğu boylamları arasındaki Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliği sınırları içerisinde çalışma alanı belirlenmiştir. Türkiye'nin Batı Karadeniz Bölgesinde yer alan Kastamonu ili doğusunda Sinop, Batısında Bartın ve Karabük, güneyinde Çankırı ve güney-doğusunda Çorum ili ile sınır oluşturmaktadır. Kuzeyinde ise Karadeniz ile çevrilidir. Kastamonu İli toprak varlığının büyük bir kısmı organik maddece zengin orman toprağı içermektedir. Bu bölgenin seçilmesindeki en önemli etmen çalışılacak arazi sınıflarının orman örtüsü haricinde başka sınıf türlerini de bulundurması olmuştur. Şekil 4.1'de çalışma alanının Türkiye ve Kastamonu İli haritasındaki genel görünümü verilmiştir.



Şekil 4.1 Çalışma alanının Türkiye üzerindeki konumu.

Kastamonu Orman Bölge Müdürlüğü, Merkez Orman İşletme Şefliğine ait çalışma alanından uygulama çalışması için yaklaşık 12 X 12 km'lik bir alan seçilmiştir. Seçilen alan içerisinde yoğun ormanlık alan mevcutken, sınıflandırma kapsamında yeterli başka alan tiplerini de bulundurmaktadır. Farklı sınıf çeşitliliğinin olması sınıflandırma sonucunda orman örtüsünün diğer sınıflara göre ayırt edilebilirliği ve sınıflandırma başarısı açısından önemlidir.

4.2. ÇALIŞMADA KULLANILAN VERİ VE YAZILIM

Uygulama çalışmasında, sınıflandırma ile detay ve öznelik tespiti için kaynak olarak kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü, sınıflandırma sonuçlarının kontrolü içinde 1/25000'lik meşcere haritası ve arazi çalışması ile sonuçlar karşılaştırılmıştır.



Şekil 4.2 Çalışma alanının yüksek çözünürlüklü Geoeye-1 uydusuna ait görüntüsü.

Bu çalışmada, uzaktan algılama teknolojilerindeki algılayıcılar gelişen olanaklarla birlikte çok sayıda metre altı mekânsal çözünürlüklere sahiptirler. Bu çalışmada piksel-tabanlı ve nesne-tabanlı sınıflandırma yöntemlerinin farklı yapılaraya sahip orman alanları için ormancılık çalışmalarına altlık olabilecek kullanılabilirliğin yüksek mekânsal çözünürlüğe sahip multispektral GeoEye-1 uydu görüntüsü üzerinden yapılması incelenmiştir. 24 320 ha alanı kapsayan Kastamonu İli çalışma alanına ait Şekil 4.2'deki GeoEye-1 uydu görüntüsü 3 Eylül 2011 tarihinde çekilmiştir. Bu görüntü üzerinden çalışma alanı olarak yaklaşık 12 X 12 km'lik bir bölge kullanılmıştır. GeoEye-1 uydusu 0.41 m pankromatik ve 1.65 m multispektral

Ormancılık çalışmalarında genellikle kızılötesi olarak alımı yapılmış görüntüler kullanılmaktadır. Bu şekilde hem kendi içlerinde hem de orman yer örtü tiplerinin diğer kesimlere göre ayırt edilebilmesi çok daha kolay olmaktadır. Bu nedenle ormancılık çalışmalarında kızılötesi enerjiye duyarlı emülsiyon veya algılayıcılar tercih edilmektedir. GeoEye-1 görüntüsünün algılayıcıları yakından incelendiğinde, ormancılık çalışmaları için büyük önem taşıyan 700 nm dalga boyundan sonraki kesime ait duyarlı yakın kızılötesi banta sahip olduğu için ağaç türlerinin tespitinde başarılı sonuçlar elde edileceği düşünülmüştür. Görüntü alınırken veri için en uygun zamanın tespit edilmesi gerekir. Yapılacak orman çalışmasının amacı, farklı orman tiplerini inceleyebilmek için görüntü üzerindeki yapraklı ve ibreli orman tiplerinin dikkate alınması, bulutluluk oranı ve kar örtüsü gibi mevsimsel özellikler dikkate alınarak görüntü 3 Eylül 2011 tarihinde alınmıştır.

Uzaktan algılama verilerinde atmosferik ve topoğrafik faktörler bir takım bozulmalara neden olurlar. Bu hataların giderilmesi için çeşitli yöntemler mevcuttur. Bu tez çalışmasında kullanılan GeoEye-1 uydu görüntüsü Kastamonu Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü hocaları tarafından başka bir projede kullanıldığı için radyometrik ve geometrik düzeltmeleri yapılmışhali ile kullanılmıştır.

Uygulamada 2011 yılına ait kullanılan GeoEye-1 uydu görüntüsünün piksel-tabanlı sınıflandırması Erdas Imagine 2015; nesne-tabanlı sınıflandırılması eCognition Developer 9.1, sınıflandırma sonuçlarının vektörleştirilmesi için ArcGIS 9.3.1 ve vektörleştirme sonuçlarının karşılaştırmalar için baz alınacak vektör veri ile sayısal olarak karşılaştırılması için de NetCAD v5.2 yazılımı kullanılmıştır.

Erdas Imagine 2015 yazılımı, Definiens firması tarafından geliştirilen uydu görüntüleri ve hava fotoğraflarının görüntülenmesi, işlenmesi, zenginleştirilmesi ve analiz edilmesi gibi işlemlerin gerçekleştirilmesini sağlayan görüntü işleme yazılımıdır. Görüntü işleme ve zenginleştirme işlemlerinde büyük kolaylıklar sağladığı için uzaktan algılama uygulamalarında da yaygın olarak kullanılmaktadır. Yazılım birçok içeriği de bünyesinde bulundurmaktadır. Verilerin görüntülenmesi, format değişikliği, ortofoto üretimi, veri çıktıları hazırlama, görüntü üzerinde uçuş simülasyonu gibi vektör veri analizleri işlemlerine uygun modüller bulunmaktadır (Erdas 2008).

eCognition Developer 9.1 yazılımı, Definiens firması tarafından geliştirilen yazılım günümüzde Trimble firmasına aittir. Sınıflandırma yöntemlerindeki eksiklik ve sınırlamaları minimuma indirmek amacı ile üretilmiştir. Nesne-tabanlı sınıflandırma yapan diğer yazılımlara göre daha kapsamlı ve olumlu sonuçlar verir. Farklı sensör ve platformlardan farklı spektral ve konumsal çözünürlükteki verinin birleştirilerek kullanılmasını sağlaması da büyük avantajlarından biridir.

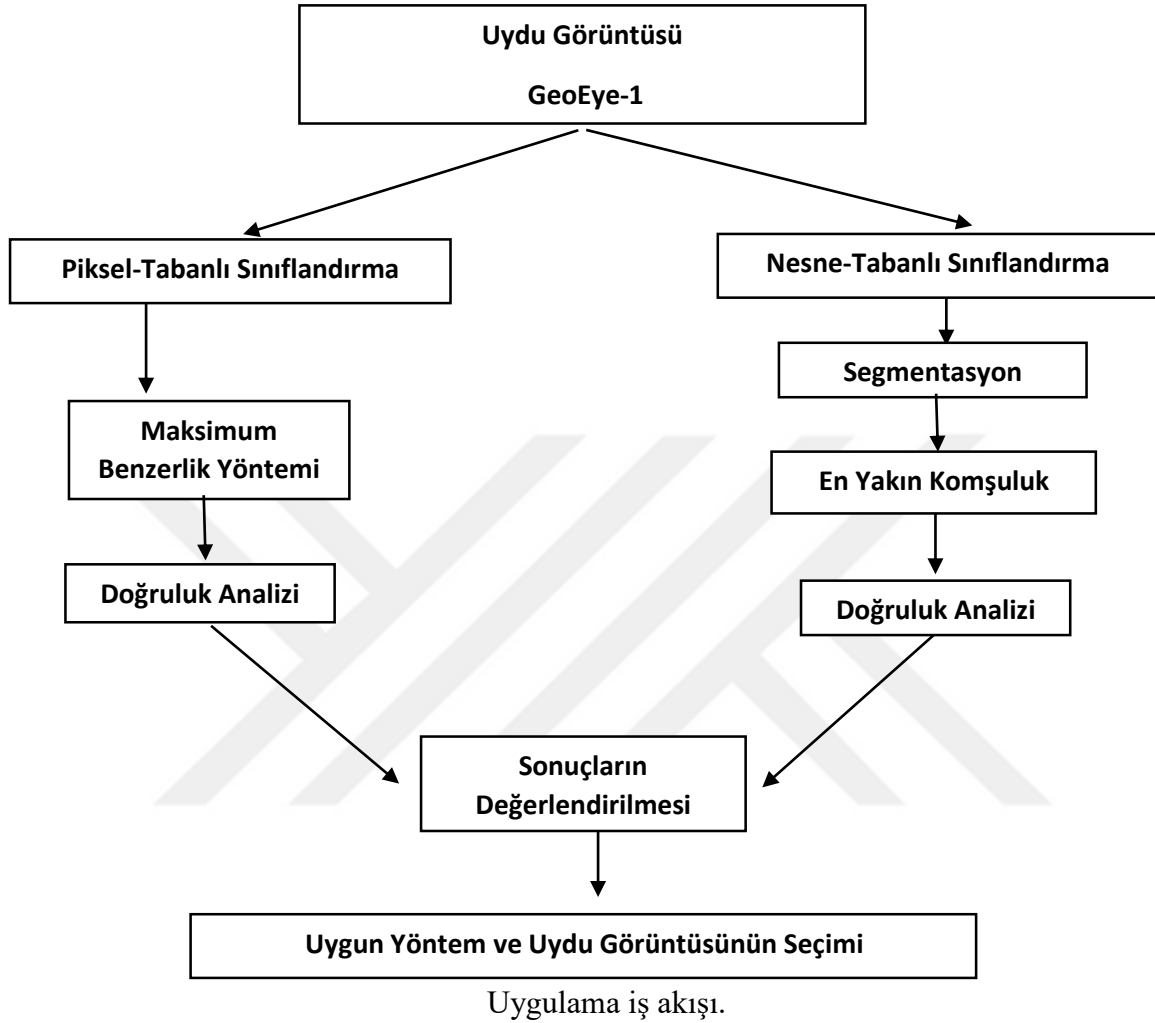
ArcGIS 9.3.1 yazılımı, ESRI firması tarafından geliştirilen Arc Map, Arc Toolboc, Arc Catalog gibi birden farklı yazılımı kapsayan büyük boyutlu bir CBS yazılımıdır. Vektör verinin oluşumundan, sonuç ürün elde edilene kadar birçok işlemi gerçekleştirebilmektedir. Kullanıcıya çok sayıda sorgulama ve analiz için imkan sağlayan ara yüze sahip olduğu için günümüzde sadece uzaktan algılamalarında değil, birçok meslek dalındaki çalışmalarda da kullanılan bir yazılım haline gelmiştir.

NetCAD v5.2 yazılımı, NETCAD Yazılım A.Ş tarafından geliştirilen NetMap, NetPro, NetSurf gibi birçok zengin menüye sahip bir yazılımdır. Vektör ve hassas koordinatlı veriyle çalışması özellikle haritacılık anlamında en çok tercih edilen program haline gelmiştir. Bu çalışmada NetCAD v5.2 yazılımı kullanılan uydu görüntüsü ve meşcere haritasının projeksiyon farklılıklarını bünyesinde bulunduran dönüşüm parametreleri ile aynı koordinat sistemine getirmeyi sağlamıştır.

4.3. METODOLOJİ

Vektörleştirme işlemleri ve karşılaştırmalarının iş akışı Şekil 4.4'te gösterildiği gibidir. Uygulama kapsamında GeoEye-1 görüntüsü kullanılarak piksel-tabanlı ve nesne-tabanlı sınıflandırma yapılmıştır. Her iki sınıflandırma için beş sınıf belirlenmiştir. Bunlardan ikisi ibreli ve yapraklı orman yer örtüsünü ifade ederken, diğer üç sınıf tarım alanı, bina ve açık alandır. Kızılötesi bant olarak alınmış uydu görüntüsünde belirgin orman yer örtüsündeki sınıfların diğer sınıflara göre ayırt edilebilirliği ve doğrulukları değerlendirilmiştir. Piksel-tabanlı sınıflandırma da maksimum benzerlik algoritması kullanılarak sınıflandırma yapılmıştır. Doğruluk analizi içinse yazılım tarafından her bir sınıf için rastgele seçilen 50 adet kontrol noktası ile sonuç elde edilmiştir. Nesne-tabanlı sınıflandırma için çoklu çözünürlük segmentasyon ve en yakın komşuluk yöntemleri kullanılarak sonuçlar elde edilmiştir. Doğruluk

analizi için Error Matrix based on Samples algoritması ile kontrol nesnelere kullanıcı tarafından seçilerek yapılmıştır.



Şekil 4.4 İş akış şeması.

4.4. PİKSEL-TABANLI SINIFLANDIRMA

Piksel-tabanlı sınıflandırma yaklaşımında kullanılan yazılım, uzaktan algılama çalışmalarında sıklıkla kullanılan Erdas Imagine 2015 olarak tercih edilmiştir. Yazılım kullanıcıya görüntü üzerinden her bir sınıfa ait serbest örnek alanlar seçtirerek sınıflandırmanın doğruluğunu güncellenebilir şekilde arttırmakta ve sahip olduğu ara yüz sayesinde de alınan örnek alanları kullanarak kolay ve başarılı sınıflandırma sonuçları elde etmektedir.


Bu çalışmada piksel-tabanlı sınıflandırma, eğitilmiş sınıflandırma yöntemleri içinden “Maksimum Benzerlik Yöntemi” seçilerek yapılmıştır. Çalışma ile ilgili bilgi aşağıda detaylı bir şekilde anlatılmıştır.

4.4.1. Geoeye-1 Uydu Görüntüsünden Piksel-Tabanlı Sınıflandırma

Piksel-tabanlı sınıflandırma işlemine başlarken görüntüden çıkartılacak anlamlı nesnelere için belirgin sınıfların tespiti yapılmalıdır. Seçilen sınıfların spektral yansıma değerleri birbirlerinden ne kadar farklı olursa sınıflandırma sonucu o kadar doğru olacaktır.

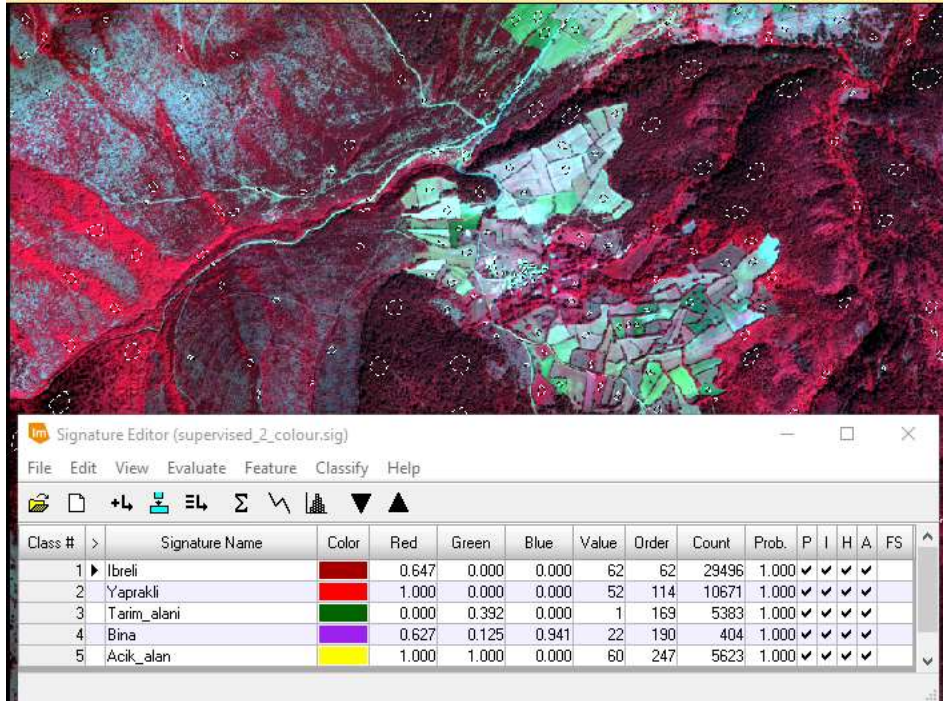
Bu çalışmada sınıflar belirlenirken kullanacağımız yüksek çözünürlüklü GeoEye-1 uydu görüntüsünün yanı sıra bölgeye ait hava fotoğrafı ve 1/25000 ölçekli meşçere haritasından da faydalanılmıştır. Bölge genel olarak ormanlık detayları bulundurmasına rağmen, farklı arazi kullanım şekli özelliklere sahip sınıflar da belirlenmiştir. Yapılan incelemeler sonucunda çalışma alanından ibreli, yapraklı, tarım alanı, bina ve açık alan olmak üzere beş sınıf belirlenmiştir. Bu sınıflar piksel-tabanlı sınıflandırma yöntemine göre sınıflandırılarak, doğruluk analizleri yapılmıştır.

Yapılan çalışma yoğun ormanlık alana ait bir uydu görüntüsü üzerinden olduğu için görüntüye ait bant sıralaması değiştirilmiş ve yeşil alanların en iyi yansıma değerine sahip olduğu kızıl ötesi bant öne çıkartılmıştır. Yapılan bu bant oranlaması sınıflara ait eğitim alanlarının seçiminde de faydalı olmaktadır. Piksel-tabanlı sınıflandırma da ilk işlem Şekil 4.5’te görüldüğü gibi kullanacağımız yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden eğitim alanlarının seçilmesidir. Eğitim alanlarının seçimi yapılırken her bir sınıf için görüntünün tamamından alanlar seçilmesi gerekmektedir. Bu hem homojen sınıflandırmayı mümkün kılacak hem de sınıflandırma da meydana gelecek hataları tek bir bölgeye değil tüm görüntüye dağıtarak, sınıflandırılacak nesnenin konumsal ve spektral olarak daha doğru sonuçlarla üretilmesini sağlayacaktır.



Şekil 4.5 Yapay renkli görüntü üzerinden eğitim alanlarının seçilmesi.

Sınıflandırmada kullanılan Erdas Image 2015 yazılımı ile seçilen örnek alanlar Şekil 4.6’da gösterildiği gibi, Raster \rightarrow Supervised \rightarrow Signature Editör menüsüne aktarılmış ve burada kullanıcı tarafından sınıflara ayrılmıştır. Sınıf tanımlama işlemi tamamlandıktan sonra “Supervised Classification” menüsü ile piksel-tabanlı sınıflandırma işlemi gerçekleştirilmiştir.



Şekil 4.6 Eğitim alanlarının birleştirilerek sınıfların oluşturulması.


Sınıflandırma yaparken hangi kontrollü sınıflandırma yönteminin seçileceği önemlidir. Bu çalışmada “Maksimum Benzerlik” yöntemi kullanılarak sınıflandırma yapılmıştır (Şekil 4.7).



Şekil 4.7 Maksimum benzerlik parametresinin seçimi.

4.4.2. Sonuç Ürünlerin Doğruluk Analizi

Bina, tarım alanı ve açık alan sınıflarının Şekil 4.8’de görüldüğü gibi bazı bölgelerde benzer yansıma değerlerine sahip oldukları görülmektedir. Buda sınıfların birbirleriyle karışmalarına neden olmakta ve sınıf doğruluğunu olumsuz etkilemektedir.




Şekil 4.8 Çalışma alanına ait yapay renkli yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.

Geoeye-1 uydu görüntüsü doğal rengiyle kullanılsaydı da Şekil 4.9’da görüldüğü gibi yine bina, tarım alanı ve açık alan sınıflarının bazı bölgelerde aynı yansıma değerlerine sahip olacağı görülmektedir. Aynı şekilde sınıfların birbirleriyle karışma durumuyla yine karşılaşılmış olunacaktı. Bu durumda belirtilen sınıfların, bant sıralama değişimlerinden büyük oranda etkilenmedikleri sonucu da ortaya çıkarmaktadır.

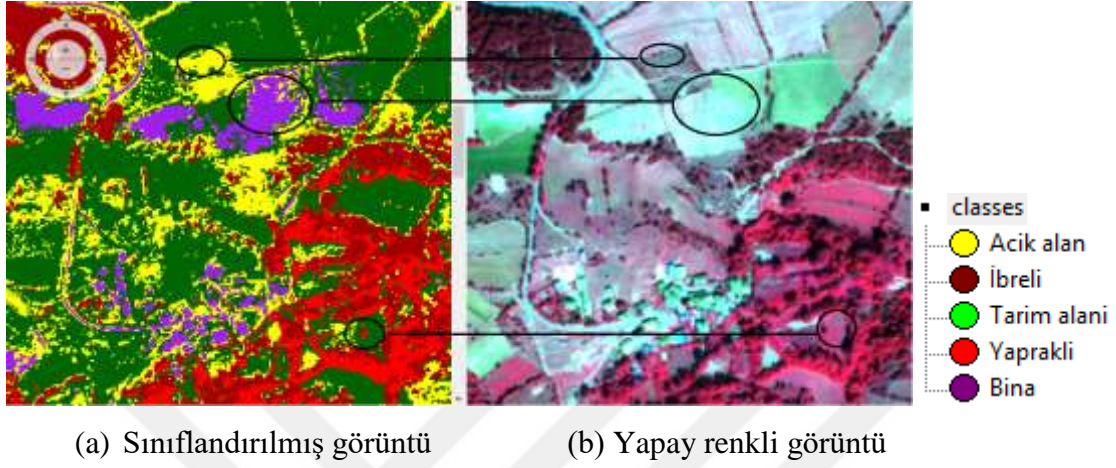


Şekil 4.9 Çalışma alanına ait yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.

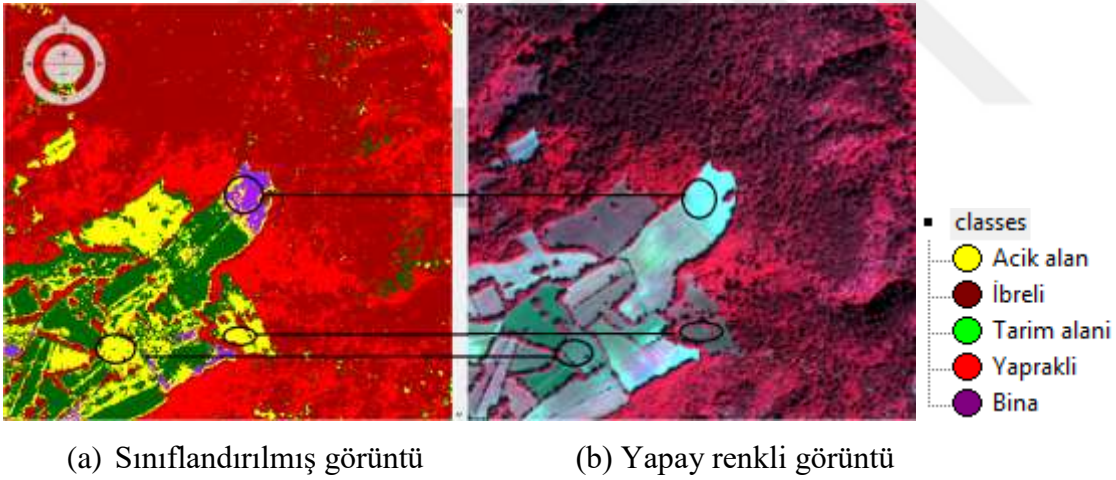


Şekil 4.10 Sınıflandırılmış yüksek çözünürlüklü GeoEye-1 uydu görüntüsü.


Doğruluk değerlendirilmesi nicel olarak yapılmadan önce Şekil 4.10’da gösterilen sınıflandırılmış görüntü ile Şekil 4.8’de gösterilen yapay renkli görüntü arasındaki yanlış sınıflandırmalarından kaynaklanan hatalar belirli alanlardan alınmış görüntülerle aşağıdaki şekillerde gösterilmiştir.



Şekil 4.11 Spektral yansımaları yakın olan nesnelerin yanlış sınıflandırılması örneği-1.




Şekil 4.12 Spektral yansımaları yakın olan nesnelerin yanlış sınıflandırılması örneği-2.



(a) Sınıflandırılmış görüntü

(b) Yapay renkli görüntü


Şekil 4.13 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-3.



(a) Sınıflandırılmış görüntü

(b) Yapay renkli görüntü

Şekil 4.14 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-4.



(a) Sınıflandırılmış görüntü


(b) Yapay renkli görüntü

Şekil 4.15 Spektral yansımaya değerleri yakın olan nesnelerin yanlış sınıflandırılması örneği-5.

Sınıflandırma sonuçlarına bütünüyle ve görsel olarak bakıldığında tarım alanı, bina ve açık alan sınıflarının benzer spektral değerlere sahip oldukları ve ayırt edilebilirliklerinin bazı kesimlerde başarısız sonuçlandığı görülmüştür. Şekil 4.11’de tarım alanı sınıfına dahil bir tarlanın sınıflandırma sonucunda bina sınıfına dahil edildiği ve aynı nesne üzerinde bu durum birkaç alanda daha tekrarlandığı görülmektedir. Tarım alanlarının orijinal görüntü üzerinde, birbirinden farklı spektral değerlere sahip olduğu da görülmektedir. Bunlardan bazılarının yansımaya değeri orman örtüsü olan ibrelili ve yapraklı sınıflarıyla da benzerdir. Şekil 4.13’te görüldüğü gibi bazı kesimlerdeki orman örtüleri spektral benzerlikten ötürü tarım alanı sınıfına dahil edilerek sınıflandırılmıştır. Şekil 4.12’de, Şekil 4.11’deki gibi tarım alanları ile binaların ayırt edilememesinden kaynaklı hatalı sınıflandırma yapılmıştır. Tarım alanı bu görüntüdeki başka bir kısımda da açık alan olarak sınıflandırılmış ve tarım alanı nesnelere bu kısımdaki sınıflandırma sonuçlarının olumsuz olduğu gözlemlenmiştir. Şekil 4.13’e genel olarak bakılırsa açık alanların yer yer tarım alanı ile karıştığı görülmektedir. Burada yoğun olarak mevcut olan ibrelili ve yapraklı sınıflarının, sınıflandırma sonuçlarında diğer nesnelere birlikte ayırt edilebilirliğinin yüksek olduğu da çıkarılabilir bir sonuçtur.

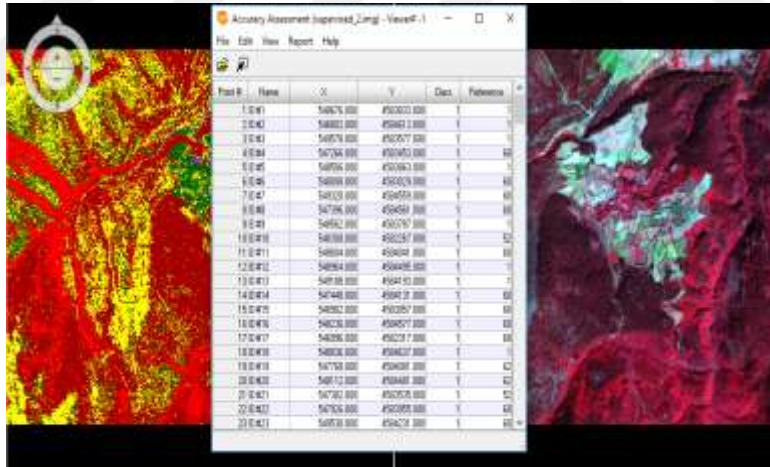
Şekil 4.14’deki en belirgin hata yol niteliğindeki açık alan sınıfının neredeyse tamamının bina sınıfı gibi davranarak sınıflandırılmış olmasıdır. Aynı durum görüntünün başka bir kesimindeki tarım alanı sınıfı için de mevcuttur. Tarım alanı sınıf başarısının bu kesimde düşük olmasının diğer bir sebebi olarakta açık alan sınıf ile büyük ölçüde spektral olarak karışmış olması gösterilebilir. Şekil 4.15’te sınıflandırma sonucunda tarım alanı, yeteri kadar örnek alan seçilmesine rağmen yapraklı sınıfıyla spektral olarak karışmış ve ayırt edilemeyerek yanlış sınıflandırılmıştır. Görüntüden alınan bu kesimde tarım alanının bina ve açık alanı ile de spektral benzerlik gösterdiği ve ayrıca da sınıflandırmanın burada özellikle tarım alanlarında başarısız olduğu sonucuna varılmıştır. Görsel olarak yapılan bu değerlendirme de orman örtü sınıfları olan yapraklı ve ibrelili sınıfları yüksek sınıflandırma başarısına sahipken; bina, tarım alanı ve açık alan sınıflarının spektral benzerlik gösterdikleri kesimlerde ayırt edilebilirliklerinin düşük olduğu sonucuna varılmaktadır.

Piksel-tabanlı sınıflandırma sonuçlarının doğrulukları sınıflandırılmamış ilk görüntünün üzerinden her bir sınıf için 50 adet kontrol noktası seçilerek toplamda beş sınıf için 250 adet nokta ile test edilmiştir (Şekil 4.16). Görüntü üzerindeki kontrol noktaları kullanıcı tarafından değil yazılım tarafından “Supervised \rightarrow Accuracy Assessment \rightarrow Add Random Point Stratified Random” parametresi seçilerek otomatik olarak atılmıştır.



Şekil 4.16 Doğruluk analizi için oluşturulan kontrol noktaları.

Atılan kontrol noktaları, kullanıcının ait olduğunu düşündüğü sınıf değer numaraları ile Şekil 4.17’de gösterildiği gibi “Reference” bölümüne girilmiştir. Burada “Class” bölümündeki sınıf numaraları yazılımın kendi oluşturduğu sınıf numaralarıdır.



Şekil 4.17 Yazılımın ve kullanıcının sınıf numaralarının tanımlanması.

Kullanıcının ve yazılımın sınıf numaraları dikkate alınarak yapılan değerlendirme sonucu Çizelge 4.2’deki değerler ile gösterilmektedir.

Çizelge 4.2 Piksel-tabanlı sınıflandırma için Kappa ve toplam doğruluk değerlendirme sonuçları.

Sınıflar	Maksimum Benzerlik		
	ÜD (%)	KD (%)	Kappa
İbrelili	%85.19	%92	0.897
Yapraklı	%85.45	%94.00	0.963
Tarım Alanı	%44.07	%52.00	0.371
Bina	%100	%10.00	0.082
Açık Alan	%57.69	%90.00	0.855
Genel Doğruluk	%67.60		
Kappa	0.595		

Piksel-tabanlı sınıflandırma sonuçları için hata matrisi incelendiğinde orman örtü sınıfları olan yapraklı ve ibrelili sınıflarının doğruluklarının diğer sınıflara göre daha başarılı olduğu görülmektedir. Ormanlık alanlarda yapılan bu çalışmalarda gerçek nesnelere yakın ve olumlu sonuçlar verdiği için piksel-tabanlı sınıflandırma yaklaşımı kullanılabilir sonucuna varabiliriz. Yukarıdaki görsel değerlendirmelerle elde ettiğimiz sonuçlar da tarım alanı, bina ve açık alan sınıflarındaki nesnelere spektral yansıma değerlerinin birbirlerine yakınlıkları nesne seçimini zorlaştırmış ve homojen nesnelere elde edilememiş, hatalı sınıflandırma sonucu alınmıştır. Erdas Imagine yazılımının “Maksimum Benzerlik” sınıflandırma yönteminin kullanılmasıyla, ibrelili, yapraklı ve açık alan sınıflarında elde edilen başarı; tarım alanı ve bina sınıflarında elde edilememiştir. En düşük doğruluk değeri bina sınıfına aittir. Bunun spektral değerler dışındaki başka bir nedeni de görüntüdeki diğer sınıflara ait nesnelere dağılım yoğunluğundan çok daha az bir alanda ve az nesne sayısına sahip olması da hem yeteri kadar örnek alan seçimini hem de kontrol işlemindeki sonuçları etkilemiştir. Piksel-tabanlı sınıflandırmanın yapıldığı bu çalışmadaki genel doğruluk % 67.60, kappa değeri ise 0.595 olarak sınıflandırma sonuçları elde edilmiştir.

4.5. NESNE-TABANLI SINIFLANDIRMA

Nesne-tabanlı sınıflandırma yaklaşımında literatürde en çok kullanılan yazılım eCognition'dır. Yazılım bant değerlerini ağırlıklandırma, fuzzy kuralları oluşturma, aynı görüntü üzerinden farklı seviyeleri aynı anda kullanmak ve farklı seviyelerde segmentasyon yapma imkanına sahiptir. Bu sebeple uygulama çalışması için eCognition yazılımı tercih edilmiştir. Yazılımı ile ilgili bu bahsedilen özellikler çalışma kapsamında aşağıda detaylı bir şekilde anlatılmıştır.

4.5.1. Segmentasyon Parametrelerinin Seçimi

Nesne-tabanlı sınıflandırmanın ilk adımı segmentasyondur. Bu sınıflandırma yönteminin başarısı büyük oranda segmentasyonun uygun parametrelerle yapılmasına bağlıdır. Sadece iyi bir segmentasyonla yapılan bir çalışma bile piksel-tabanlı sınıflandırmaya göre çok daha iyi sonuçlar vermektedir (Yan et al. 2006).

Çalışmada çoklu çözünürlük (multi resolution) segmentasyon yöntemi kullanılmıştır. Aşağıdaki parametrelerin deneme yanılma yöntemiyle en iyi sonuç veren değerleri seçilerek segmentasyon yapılmıştır. Çizelge 4.3’de farklı seviyelerle tanımlanmış parametreler mevcuttur. 20 farklı seviyede segmentasyon yapılmış ve farklılıkları aşağıda gösterilen şekillerde gösterilmiştir.


Çizelge 4.3 GeoEye-1 uydu görüntüsü için segmentasyon parametreleri.

SEVİYE	ÖLÇEK	ŞEKİL	BÜTÜNLÜK
1	50	0.1	0.5
2	50	0.3	0.5
3	50	0.5	0.5
4	50	0.7	0.5
5	50	0.9	0.5
6	100	0.1	0.5
7	100	0.3	0.5
8	100	0.5	0.5
9	100	0.7	0.5
10	100	0.9	0.5
11	150	0.1	0.5
12	150	0.3	0.5
13	150	0.5	0.5
14	150	0.7	0.5
15	150	0.9	0.5
16	200	0.1	0.5
17	200	0.3	0.5
18	200	0.5	0.5
19	200	0.7	0.5
20	200	0.9	0.5


Ölçek parametresi direk olarak nesne boyutunu etkileyen bir faktördür. Bu değer ne kadar büyük olursa oluşacak nesnelere de o kadar büyük şekillerde oluşacaktır. Çalışmada en uygun ölçek parametresinin seçimi için farklı parametrelere sahip seviyeler tanımlanarak en doğru sonucu veren değerler seçilmiştir. Görüntü yoğun olarak orman arazi tiplerini içerirken bazı kısımlarda tarım alanı, bina ve açık alan sınıflarına ait yerler mevcuttur. Bina gibi daha detaylı objeler ile değil de kalabalık ağaç türleriyle çalışıldığı için ölçek parametresi 50'den başlatılarak 100, 150 ve 200 olmak üzere dört farklı kombinasyonda her sınıf için değerlendirilmesi yapılmıştır. Seçilen ölçek parametresi büyüdükçe nesnelere de büyüdüğü ve homojenliklerini kaybettiği görülmüştür. Yanlış seçilecek parametre örneğin, yol olan bir yer için yolun bağlandığı tarlayı da içine alarak yanlış segmentasyon sonucunu verir. Bu gibi karşılaşılabilecek durumlarda farklı kombinasyonlardaki ölçek parametrelerinin görsel sonuçlarına bakılmalıdır.

Şekil parametresinin nesneye olan etkisi ölçek kadar değildir. Ama nesnenin şekil değiştirme ve spektral özelliklerini içermesi bakımından önemli bir rolü vardır. Parametre 0.1 ile 0.9 değerleri arasındaki, kullanıcı tarafından seçilen bir değer belirlenir. Şekil parametresi büyüdükçe nesnelere spektral özellikleri kaybolur ve oluşacak nesnelere spektral benzerlik sağlamayan diğer nesnelere birleşerek rasgele nesnelere oluşur.


Bütünlük parametresinin segmentasyona diğer iki parametre kadar etkisi yoktur. Nesne sınırlarının daha yumuşatılarak oluşumunda etkilidir. Aşağıda Şekil 4.18, Şekil 4.19, Şekil 4.20 ve Şekil 4.21'de; seçilen ölçek, şekil ve bütünlük parametreleri her bir sınıf için görüntüden kesit alınarak sonuçları karşılaştırılmıştır.



(a) İbrelî, yapraklı ve açık alan sınıf türü




(b) Tarım alanı sınıf türü




(c) Bina sınıf türü

Ölçek : 50
Şekil : 0,1
Bütünlük : 0,5


Şekil 4.18 Farklı parametreler ile segmentasyon sonucu örneği-1.



(a) İbrelî, yapraklı ve açık alan sınıf türü




(b) Tarım alanı sınıf türü




(c) Bina sınıf türü

Ölçek : 100
Şekil : 0,3
Bütünlük : 0,5


Şekil 4.19 Farklı parametreler ile segmentasyon sonucu örneği-2.



(a) İbrelı, yapraklı ve açık alan sınıf türü



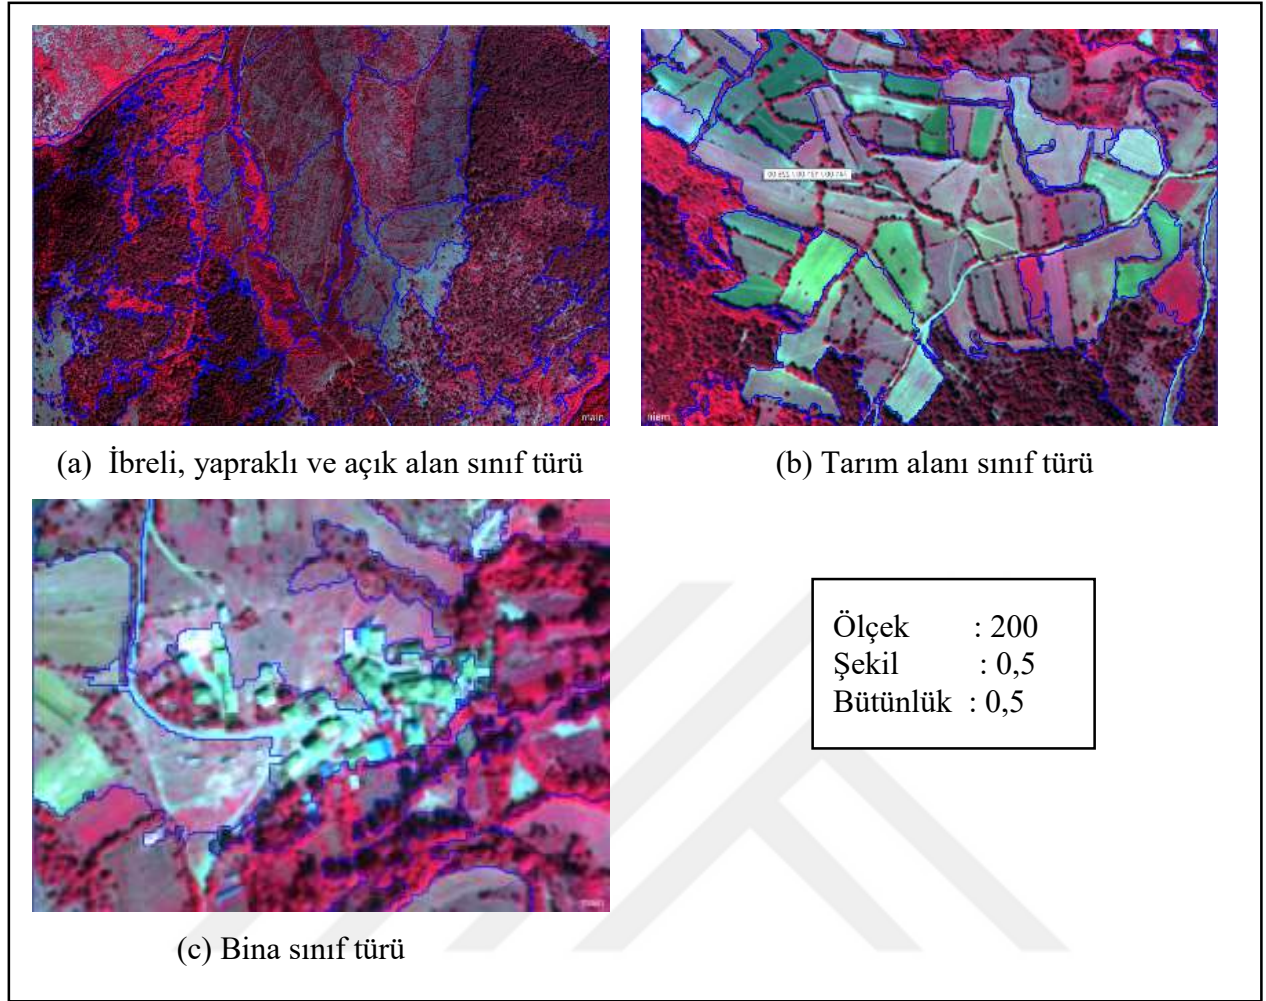
(b) Tarım alanı sınıf türü



(c) Bina sınıf türü

Ölçek : 150
Şekil : 0,9
Bütünlük : 0,5

Şekil 4.20 Farklı parametreler ile segmentasyon sonucu örneđi-3.



Şekil 4.21 Farklı parametreler ile segmentasyon sonucu örneği-4.

Şekillerdeki görüntülerde farklı parametre değerleriyle yapılmış segmentasyon sonuçları gösterilmiştir. Ölçek parametresi 50, 100, 150, 200 seçilirken; şekil parametreleri 0.1, 0.3, 0.5, 0.7, 0.9 ve bütünlük parametresi bütün seviyelerde 0.5 alınarak değerlendirme yapılmıştır. Ölçek parametresi büyüdükçe nesnelere büyüdüğü ve gerçek nesne özelliklerini yansıtmadığı görülmüştür. Bu gibi kaba ölçekler segmentasyon aşamasında farklı spektral özelliklere sahip nesnelere de içine katarak anlamsız nesnelere oluşmasına neden olmaktadır. Ölçek parametresi 50 seçilen görüntülerde nesnelere gerçekteki arazi şekillerine daha çok benzediği de görülmektedir. Şekil parametresi seçilirken nesnelere şekillerindeki yumuşatma oranına dikkat edilmiştir. Şekillerdeki görüntülere bakıldığında parametre değeri arttıkça nesnenin, gerçekteki nesne özelliğinden uzaklaştığı ve spektral bozulmaya uğradığı görülmektedir. Buradan en iyi sonuçların küçük parametre değerlerinin verdiğini söyleyebiliriz. Bütünlük parametresinin seçimi nesnelere üzerinde fazla bir değişikliğe neden olmadığı için uygun tek bir

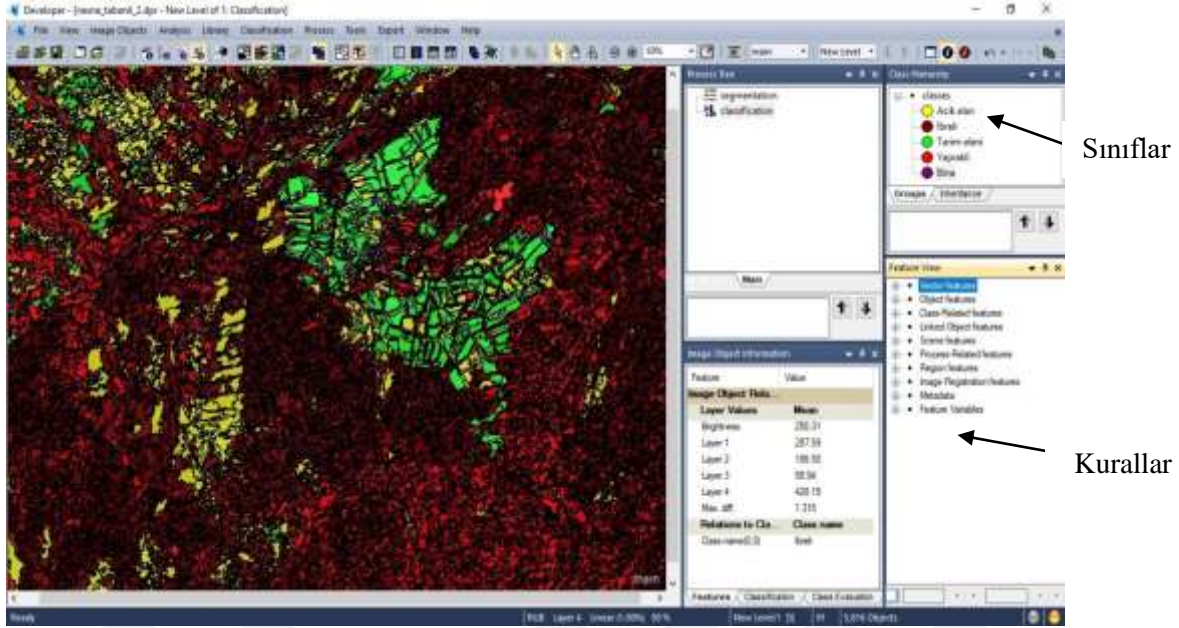
değer kullanılmıştır. Tarla sınırları ve bina yapılarında bazı alanlar küçükte olsa bir değişim göstermiştir. Kullanılan 0.5 değeri nesnelere için yeterli bütünlük ve yumuşaklığı sağladığı için seçilmiştir. Bu çalışmada farklı seviyelerde segmentasyon sonuçlarına bakılmış ve en uygun değerlerin ölçek parametresi için 50, şekil parametresi için 0.1 ve bütünlük parametresi için de 0.5 olmasına karar verilerek segmentasyon işlemi yapılmış ve sınıflandırma işlemine geçilmiştir.

4.5.2. GeoEye-1 Uydu Görüntüsünden En yakın Komşuluk Yöntemiyle Sınıflandırma (Nearest Neighbour)

Bu çalışmada eCognition yazılımının içindeki sınıflandırma yöntemlerinden en yakın komşuluk sınıflandırma yöntemi seçilerek uygulama yapılmıştır. En yakın komşuluk sınıflandırması segmentasyon işleminden sonra oluşan görüntü nesnelere her bir sınıf için örnek alanların seçilmesiyle yapılmaktadır.

Segmentasyon ve sınıflandırma birbirlerine bağlı ve direkt sonucu etkileyen işlemlerdir. Segmentasyon işleminde seçilen parametrelerin görüntüleri gerçek yeryüzü nesnelere hem şekilsel hem de spektral olarak yansıtması istenir. Bu alanlar seçilirken örneğin, bina sınıfı için örnek alan seçilirken doğru nesneyi yansıtan kısımlardan seçilmesi beklenir. Bunun dışında binalara yakın yansıma değeri olan bir tarım alanı ile birleşerek bir nesne oluşturulduğunda sınıflandırma sonucu da olumsuz etkilenecektir.

Seçtiğimiz parametreler tüm sınıflar için homojen nesnelere oluşmasını sağlamıştır. Bu nesnelere üzerinden her bir sınıf için örnek alanlar seçilerek yazılıma tanıtılmıştır.




Şekil 4.22 eCognition yazılımı ile sınıflar ve kuralların tanımlanması.

Sınıflandırmada önemli olan ve dikkat edilmesi gereken nokta, görüntü üzerindeki nesnelere örnek alanlar seçilirken her bir sınıf ve alandan homojen bir şekilde ve aynı oranda alınarak yapılması gerektiğidir. Aksi takdirde sınıflandırmada çıkabilecek hatalar yoğun olarak örnek alınan alana dağıtılır ve kalan alan gerçek görüntüden tamamen bağımsız sonuçlar verebilir. Sınıflar “ Class Hierarchy” penceresinden tanımlanmıştır. Sınıflara ait seçilen nesnelere için “ Feature View” bölümünde, yansıma değerleri ve geometrik yapılarına ilişkin kurallar tanımlanarak sınıflandırma doğruluğunun artırılması ve her nesne için detaylı bilgi alınabilmesi sağlamıştır (Şekil 4.22).


4.5.3. Sonuç Ürünlerin Doğruluk Analizleri

Yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden yapılan nesne-tabanlı sınıflandırmada ibrelî, yapraklı, tarım alanı, bina ve açık alan olmak üzere beş adet sınıf belirlenmiştir. Sınıflandırma yaparken kullanılan yazılım eCognition’dır. Yazılım bizlere farklı sınıflandırma yöntemleri sunmuş ve uygulamada en yakın komşuluk (nearest neighbour) yöntemi seçilerek nesne-tabanlı sınıflandırma sonucu elde edilmiştir.




Şekil 4.23 Sınıflandırılmış GeoEye-1 uydu görüntüsü.


Doğruluk değerlendirilmesi nicel olarak yapılmadan önce Şekil 4.23'deki sınıflandırılmış görüntü ile yapay renkli görüntü arasındaki yanlış sınıflandırmalardan kaynaklanan hatalar belirli alanlardan alınmış görüntülerle aşağıdaki şekillerde gösterilmiştir.




Şekil 4.24 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-1.




Şekil 4.25 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-2.



Şekil 4.26 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-3.



Şekil 4.27 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-4.

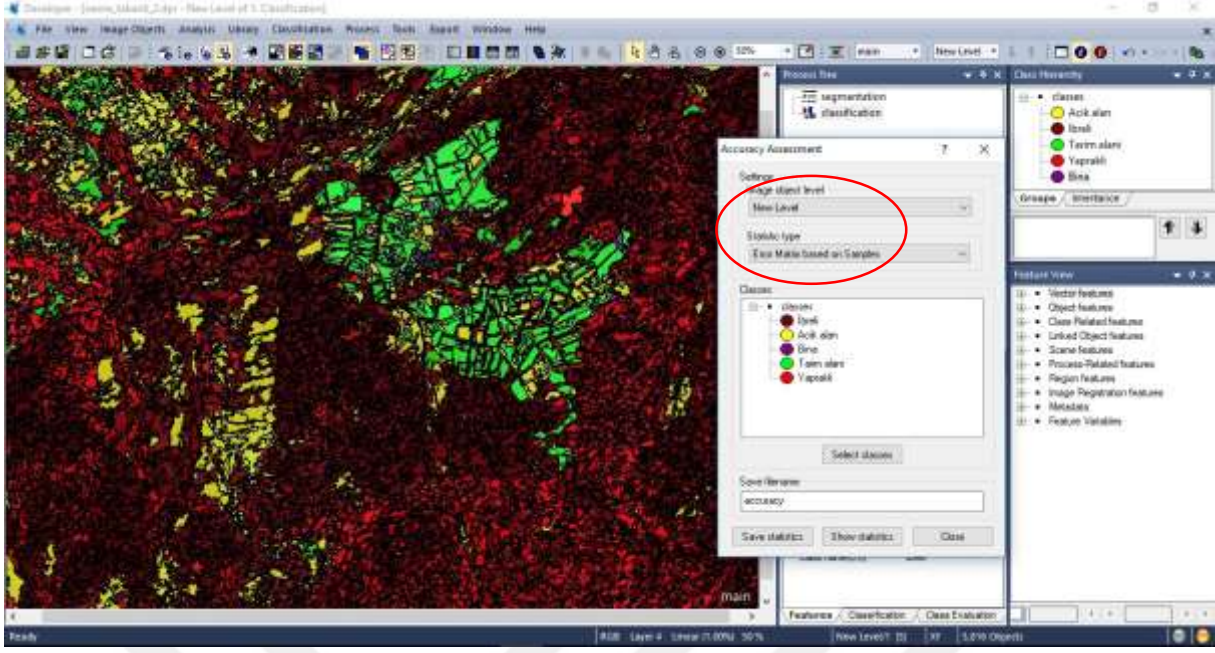


Şekil 4.28 Nesne-tabanlı sınıflandırma sonuçlarının görsel olarak incelenmesi örneği-5.

Yukarıdaki şekillerdeki yapay renkli görüntü ile sınıflandırılmış görüntülere bakıldığında, spektral benzerliklerinden dolayı birbirleriyle en fazla karışan sınıfların bina, tarım alanı ve açık alan sınıflarının olduğu görülmektedir. Sınıflandırılmış görüntüye genel olarak bakıldığında orman örtüsü içerisindeki “İbrelı ve Yapraklı” sınıfları çoğunlukla gerçek nesnelere yansıtacak

şekilde sınıflandırılmışlardır. Buda bizlere spektral olarak nesnelere rahatlıkla birbirlerinden ayırt edilebilirliğini göstermektedir. Yukarıdaki kıyaslamalara bakıldığında Şekil 4.24'te, içerisinde azınlıkta orman örtüsü olan açık arazinin bazı kısımlarında tarım alanı olarak sınıflandırıldığını, bunun tam tersi olarak tarım alanının belirli kısımlardaki sınıflandırma sonuçlarında oluşan nesnelere açık alan sınıf türü olarak sınıflandırılmış olduğunu görmekteyiz. Şekil 4.25'de ibreli sınıfının, sınıflandırılmış görüntünün bazı kesimlerinde yapraklı sınıfıyla karıştığı görülmektedir. Aynı şekildeki bir diğer sınıflandırma hatasının yapraklı sınıfının içerisinden geçmesi gereken yol niteliğindeki açık alan sınıfının yapraklı sınıfıyla karıştığı görülmektedir. Şekil 4.26'da yine yol olarak gözükken ve açık alan olarak sınıflandırılmış olması gereken nesne tamamen kapanmış ve o alan ibreli sınıfına dahil edilerek sınıflandırılmıştır. Diğer bir hata açık alan içerisindeki sayıca az olarak görülen ibreli orman örtüsünün sınıflandırma sonucunda baskın olarak açık alandan çok ibreli sınıfı ile sınıflandırılmış olmasıdır. Şekil 4.27'deki tarım alanı, açık alan ve binaların benzer spektral özellik göstererek hatalı sınıflandırıldığını görmekteyiz. Şekil 4.28'de tarım alanlarının etrafında yapraklı orman örtüsünün mevcut olduğu ve bazı tarım alanlarının spektral yansıma değerlerinin de bu orman örtüsüyle benzer özellikte olduğu görülmektedir. Sınıflandırma sonucunda bu alanın neredeyse tamamı tarım alanı özelliğini kaybederek, benzer yansıma değerine sahip olan yapraklı ve ibreli sınıf türlerine dahil edilerek sınıflandırılmıştır. Aynı şekilde diğer şekillerde de görülen açık alanların benzer spektral özelliklere sahip tarım alanı olarak sınıflandırıldığı ve o alandan geçen yol niteliğindeki açık alan sınıfının tamamen özelliğini kaybederek sınıflandırıldığı görülmektedir.

Sınıflandırma doğruluğunun analizi için eCognition yazılımındaki Tools → Accuracy Assessment → Statistic Type Error Matrix based on Samples yöntemi seçilerek yapılmıştır (Şekil 4.29). Bu yöntem için segmentasyonda seçtiğimiz örnek alanlar gibi analiz içinde görüntü üzerinden homojen dağılımlı alanlar tekrardan seçilerek yapılmaktadır. Yapılan analiz sonucu Çizelge 4.4'de verilmiştir.



Şekil 4.29 Doğruluk analizi için seçilen “Error Matrix based on Samples” yöntemi ile yeniden örnek alanların seçilmesi.

Çizelge 4.4 Nesne-tabanlı sınıflandırmaları için Kappa ve toplam doğruluk değerlendirme 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 Kapa	%90.59		0.872

Çizelge 4.4’teki hata matrisi incelendiğinde “İbrelili ve Yapraklı” sınıflarının yüksek doğruluklara sahip olduklarını görülmektedir. Ormanlık alanlarda yapılan çalışmalarda bu sınıfların birbirlerinden eCognition yazılımı kullanılarak nesne-tabanlı sınıflandırma yöntemi ile yakın sınıflandırma doğruluklarına sahip oldukları da görülmektedir. Yukarıdaki şekillerde verilen görüntülerde de görsel olarak yorumlandığında bazı bölgelerde benzer spektral değerlere sahip olmalarından dolayı ayırt edilebilirliğin olmadığı sonucu varılmaktadır. Genel olarak gerçek nesne özelliklerine çok yakın sınıflandırma sonuçları alınmıştır. Tarım alanına bakıldığında bina ve açık alana göre daha yüksek doğruluk elde edilmiştir. Bazı bölgelerde

spektral deęerleri bu iki sınıfa benzer özellik gösterdiğinden dolayı yanlış sınıflandırılan bölgeler doğruluk oranını düşürmüştür. Genel doğruluk oranının %90.59, kappa deęerinin ise 0.872 olduđu bu çalışmada nesne-tabanlı sınıflandırma sonuçlarının bütün sınıflar için farklı doğruluk deęerlerine sahip olmakla birlikte başarılı bir sınıflandırma yapıldığının sonucunu vermektedir.

4.5.4. Nesne-Tabanlı ve Piksel-Tabanlı Sınıflandırma Sonuçlarının Karşılaştırılması

Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinde yapılan piksel-tabanlı ve nesne-tabanlı sınıflandırma sonuçlarının karşılaştırılması bütün sınıflar için Çizelge 4.5'te görüldüğü gibidir. Nesne-tabanlı sınıflandırma sonucunda genel doğruluk %90.59 iken piksel-tabanlı sınıflandırma sonucunda genel doğruluğun %67.60 olduđu görülmektedir. Uygulamadaki beş sınıf için deęerlendirme yapılacak olursa orman örtü tipini yansıtan ibrelili ve yapraklı sınıfları her iki sınıflandırma yönteminde de ayırt edilebilir ve başarılı sonuçlar vermişlerdir. Kullanılan GeoEye-1 uydu görüntüsündeki mevcut yakın kızılötesi bant sayesinde orman örtüsü çeşitliliği başarılı bir şekilde sonuçlara yansımıştır. Bina, tarım alanı ve açık alan sınıfları karşılaştırıldığında başarı yüzdesi olarak nesne-tabanlı sınıflandırma, piksel-tabanlı sınıflandırmaya göre gerçeğe yakın sonuçlar vermiştir. Sınıflandırma sonuçlarına göre en belirgin fark bina sınıfında ortaya çıkmıştır. Ormanlık alan içerisinde hem detaylı oluşu hem de dięer sınıfların dağılımına göre daha az yer kaplaması ve spektral yansıma deęerlerinin bazı durumlarda açık alan ve tarım alan sınıflarıyla benzer sonuçlar vermesi bu sonucu ortaya çıkartmıştır.

Çizelge 4.5 Piksel ve nesne-tabanlı sınıflandırma sonuçlarının karşılaştırılması (%).


Yöntem Sınıflar	Nesne-Tabanlı Sınıflandırma/ Maksimum Benzerlik (%)			Piksel-Tabanlı Sınıflandırma/ En Yakın Komşuluk (%)		
	ÜD (%)	KD (%)	Kappa	ÜD (%)	KD (%)	Kappa
İbrelili	%93.58	%97.22	0.897	%85.19	%92	0.897
Yapraklı	%97.17	%88.80	0.963	%85.45	%94.00	0.963
Tarım alanı	%78.57	%91.67	0.748	%44.07	%52.00	0.371
Bina	%75	%81.81	0.744	%100	%10.00	0.082
Açık alan	%89.89	%81.63	0.873	%57.69	%90.00	0.855
Genel doğruluk	%90.59			%67.60		
Kappa	0.872			0.595		

Ormanlık çalışmalarında altlık olabilecek bir durum için piksel ve nesne-tabanlı sınıflandırma sonuçları kullanılabilirken, benzer yansıma değerine sahip nesnelere ya da yol, bina gibi daha küçük detayların çıkarımında piksel-tabanlı sınıflandırma sonuçlarının altlık olarak kullanılmayacağı sonucu çıkarılmıştır.


4.5.5. Nesne-Tabanlı Sınıflandırma Sonuçlarının Vektör Veri Haline Çevrilmesi

Çalışmada uygulanan piksel-tabanlı ve nesne-tabanlı sınıflandırma sonuçları yukarıda gösterilmiştir. Nesne-tabanlı sınıflandırma analizi tüm sınıflar için başarılı sonuçlar verirken, piksel-tabanlı sınıflandırma sonuçları bazı sınıflar için istenilen doğruluğu sağlamamıştır. Bu yüzden sadece başarılı sonuçlar veren nesne-tabanlı sınıflandırma sonuçları dikkate alınarak vektörel karşılaştırmaların yapılmasına karar verilmiştir.


Nesne-tabanlı sınıflandırma sonuçları, kullanılan eCognition yazılımı ile kolaylıkla vektör veri haline çevrilmiş olup diğer vektör verileriyle karşılaştırma yapmak için de CBS uygulamalarına kolaylık sağlamıştır. Görüntüdeki tüm sınıflar “export” menüsü ile vektör veri haline getirilmiş ve “*.shp” uzantılı dosya olarak kaydedilmiştir. Kaydedilen dosya NetCAD v5.2 yazılımı ile “*.NCZ” uzantılı olarak Şekil 4.30, Şekil 4.31, Şekil 4.32, Şekil 4.33 ve Şekil 4.34’te gösterildiği gibi her bir sınıf için üzerinde çalışılmak üzere vektör veri olarak saklanmıştır.



Şekil 4.30 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “İbrelî” sınıfının vektör verileri.




Şekil 4.31 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Yapraklı” sınıfının vektör verileri.



Şekil 4.32 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Tarım alanı” sınıfının vektör verileri.



Şekil 4.33 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Açık alan” sınıfının vektör verileri.



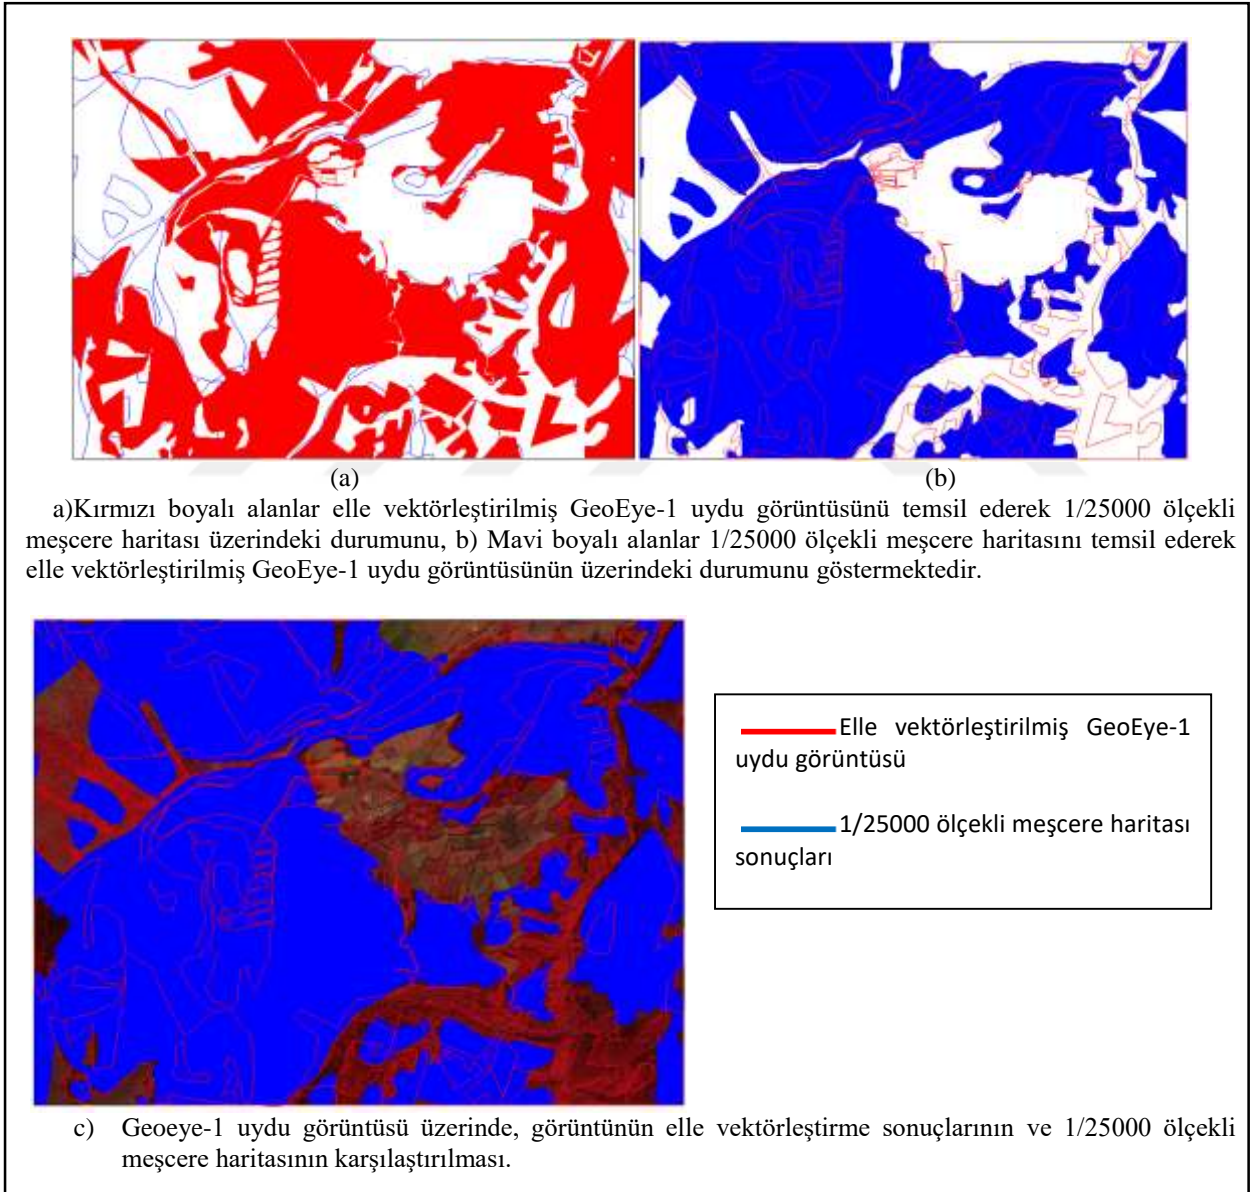
Şekil 4.34 Nesne-tabanlı sınıflandırma sonuçlarından elde edilen “Bina” sınıfının vektör verileri.

4.6. CBS ORTAMINDA DEĞERLENDİRME


CBS ortamında değerlendirme yapmak için yazılım sorgulama ve analizi bulunan, raster ve vektör yapıya sahip, farklı yazılımda bile oluşturulabilen her bir sınıfı kendi içinde tekrar tanımlayabilen yapısı ile NetCAD v5.2 yazılımının kullanılmasına karar verilmiştir. Aşağıda, elle vektörleştirilmiş GeoEye-1 uydu görüntüsü baz alınarak, nesne-tabanlı sınıflandırma sonucunun vektör verisi ile ormancılık çalışmalarında altlık olarak sıklıkla kullanılan 1/25000 ölçekli meşcere haritasına ait vektör verinin karşılaştırılması, sınıfların birbirleri ile hem görsel hem de sayısal değerlendirilmeleri yapılmıştır.

4.6.1. Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü ile 1/25000 Ölçekli Meşcere Haritası Sonuçlarının Karşılaştırılması

Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsünün elle vektörleştirilmesinin ardından 1/25000 ölçekli meşcere haritası ile tüm sınıflar için aşağıdaki şekillerdeki görüldüğü gibi hem görsel olarak değerlendirme yapılmış ve hem de Çizelge 4.6 'da ki gibi sayısal olarak analizleri yapılmıştır.




Şekil 4.35 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “İbrelî” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



(a)

(b)

a) Kırmızı boyalı alanlar elle vektörleştirilmiş GeoEye-1 uydu görüntüsünü temsil ederek 1/25000 ölçekli meşcere haritası üzerindeki durumunu, b) Mavi boyalı alanlar 1/25000 ölçekli meşcere haritasını temsil ederek elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün üzerindeki durumunu göstermektedir.

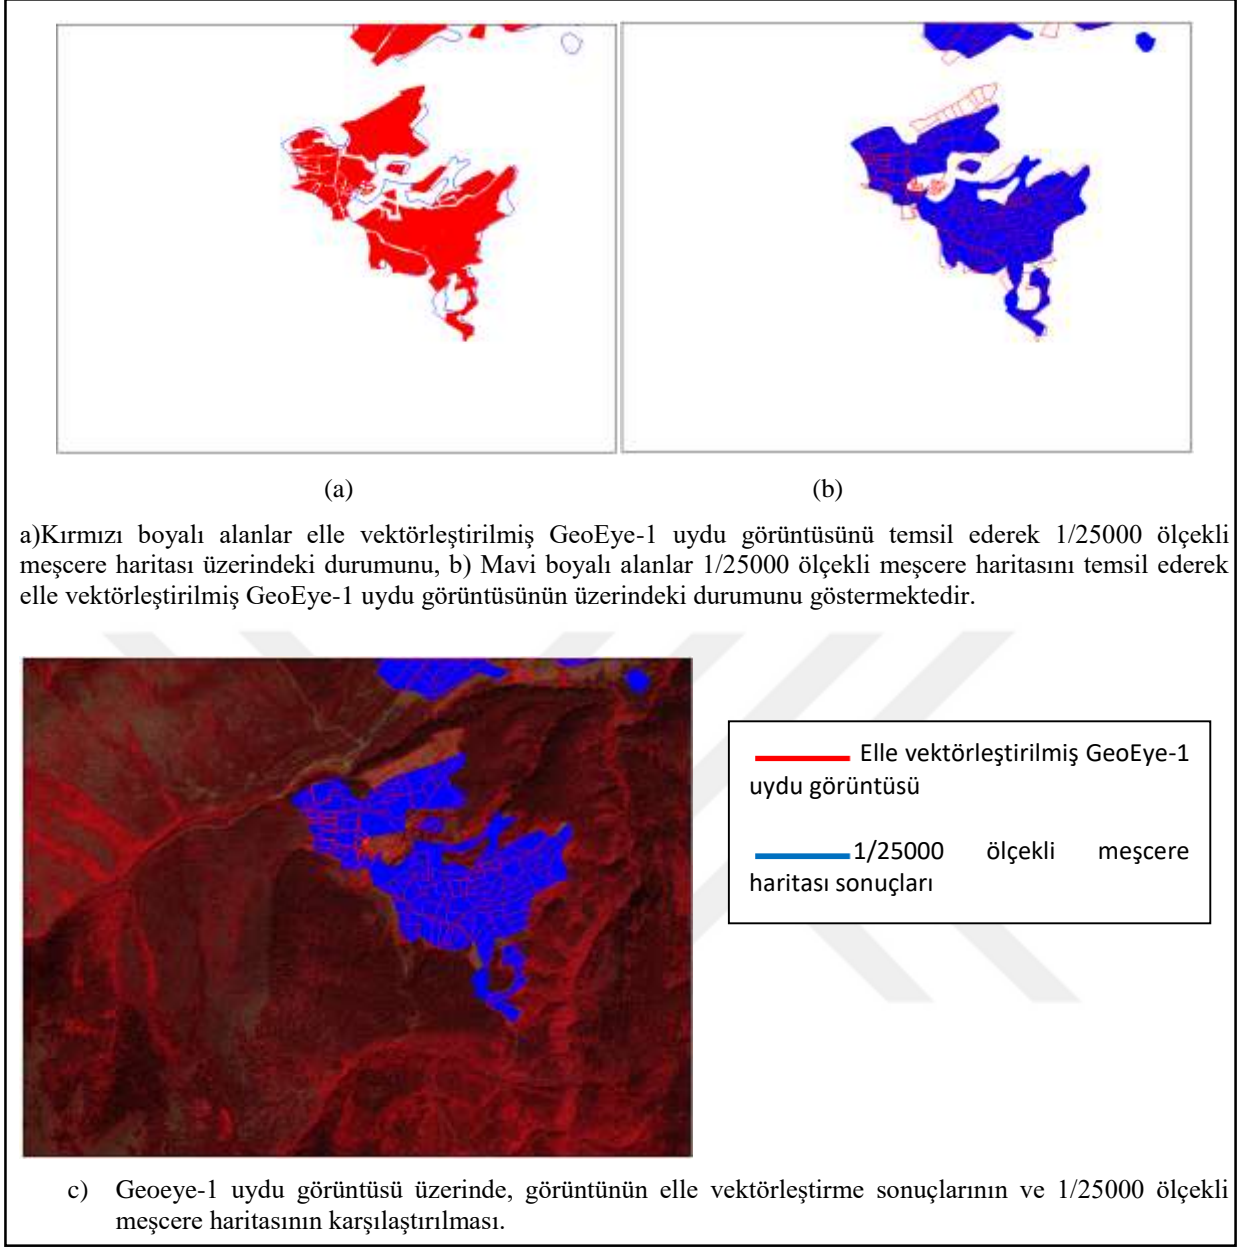


— Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü

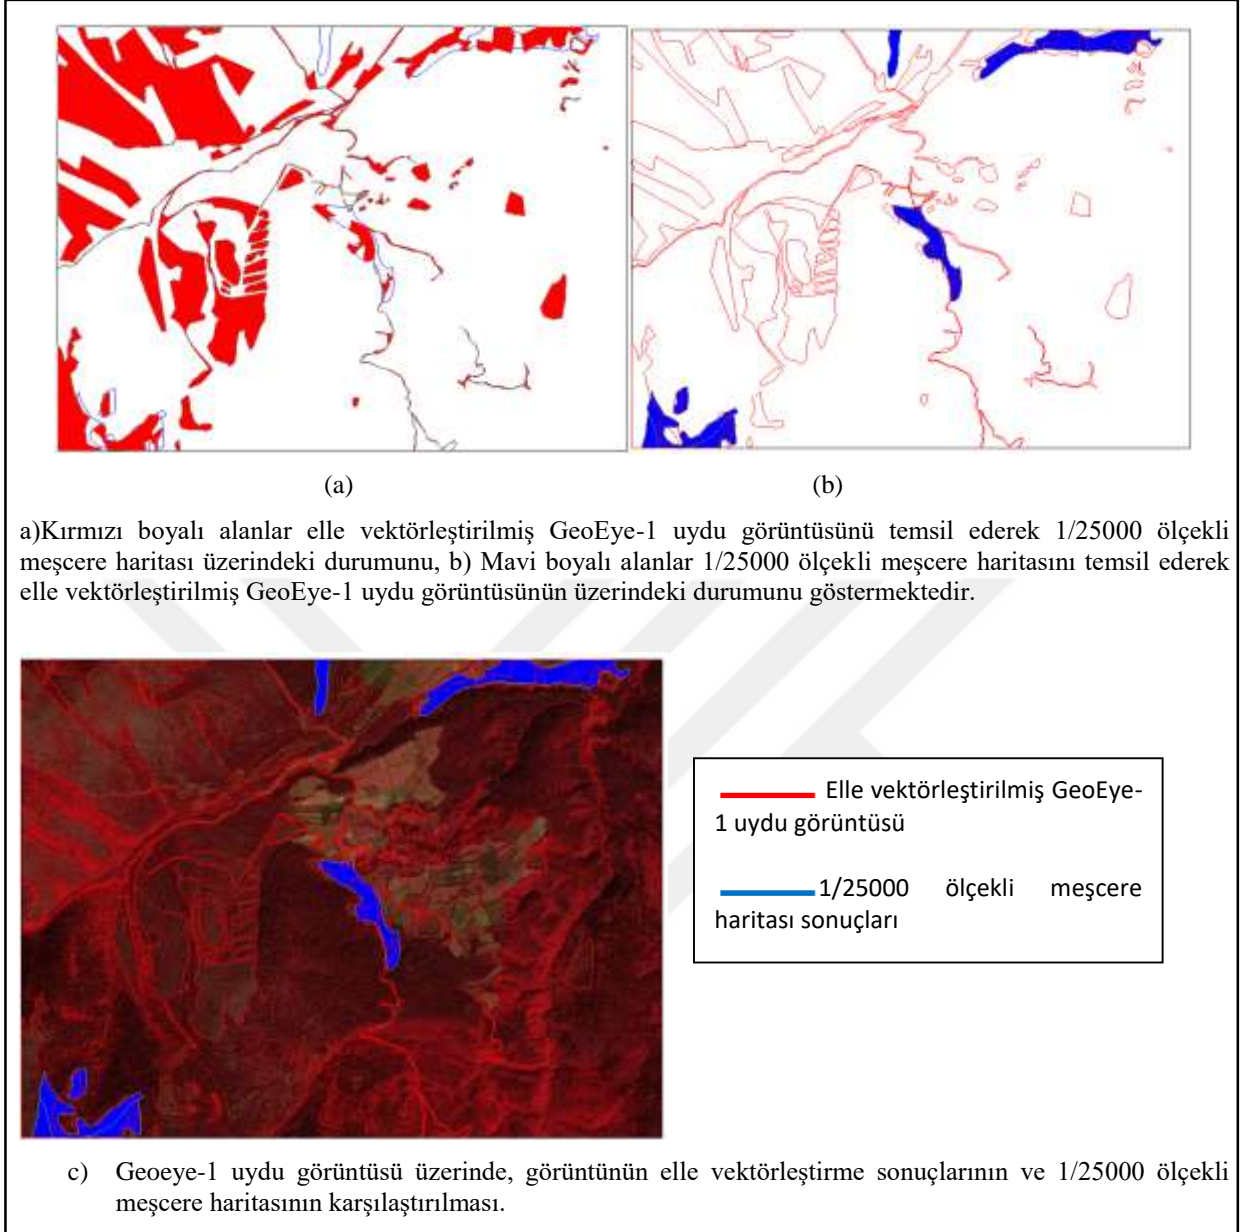
— 1/25000 ölçekli meşcere haritası sonuçları

c) Geoeeye-1 uydu görüntüsü üzerinde, görüntünün elle vektörleştirme sonuçlarının ve 1/25000 ölçekli meşcere haritasının karşılaştırılması.

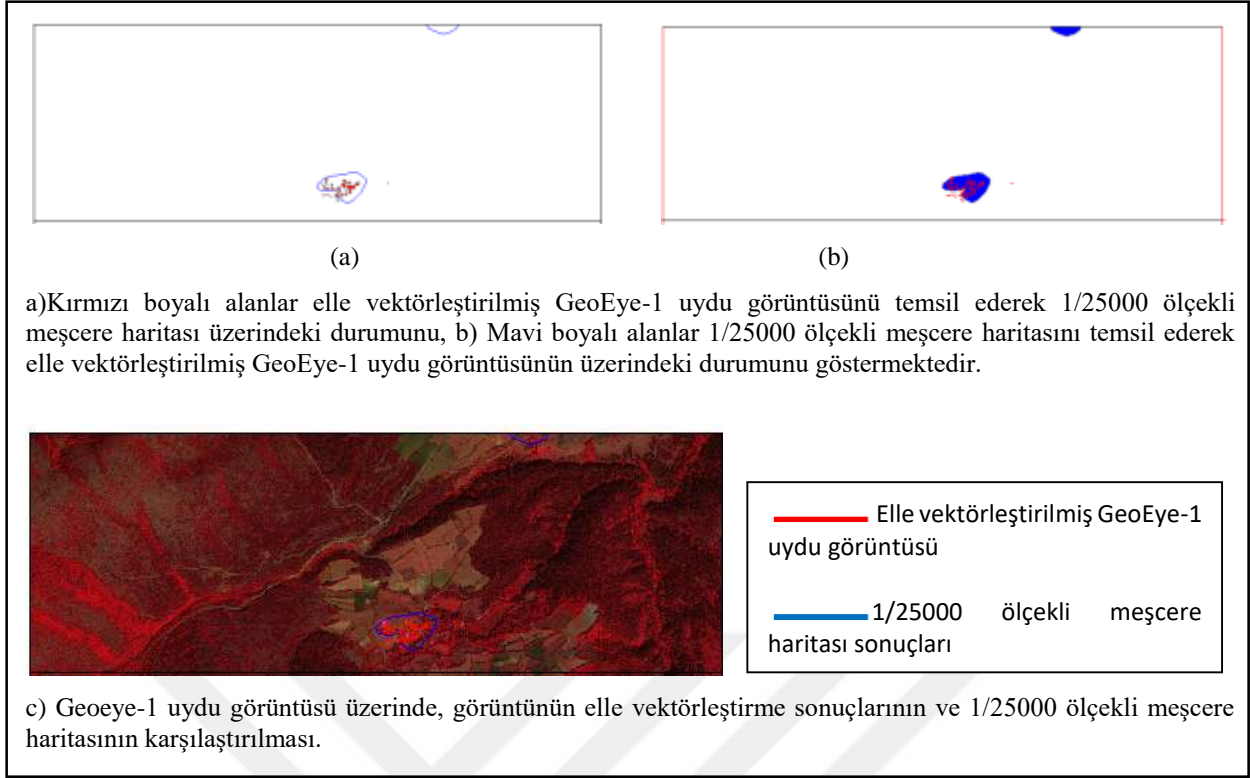
Şekil 4.36 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Yapraklı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



Şekil 4.37 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Tarım Alanı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



Şekil 4.38 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşcere haritası üzerinden “Açık Alan” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



Şekil 4.39 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve 1/25000 ölçekli meşçere haritası üzerinden “Bina” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.

GeoEye-1 uydu görüntüsü üzerinden seçilen 12 x 12 km’lik dış sınır meşçere haritası üzerine atılmış, hem görsel hem de sayısal olarak sonuçları karşılaştırılmıştır. Kullanılan meşçere haritası, çalışma alanı olan Kastamonu Orman Bölge Müdürlüğünden temin edilmiş olup tapuya tescilli olduğu için geometrik doğruluğu sorgulanmadan kullanılmıştır. Yukarıdaki şekillere bakıldığında sınıflara ait bazı alanlarda kayıklıklar olduğu görülmektedir. Bu kayıklığın sebebi yüksek çözünürlüklü uydu görüntüsü ile aynı geometrik doğruluğa sahip olmaması gösterilebilir. Meşçere haritaları sayısallaştırılırken kullanılan kontrol noktaları, seçilen eşyükselti eğrileri, operatörün hatası, büyük ölçekle üretilmeleri ve eski olmalarından dolayı yıpranma payları gibi birçok sebep yüksek geometrik doğruluğa sahip olmamalarını açıklayabilir. Çizelge 4.6’da elle vektörleştirilmiş uydu görüntüsü ve 1/25000 ölçekli meşçere haritası üzerinden NetCAD v5.2 yazılımı kullanılarak tüm sınıflar için yapılan sayısal değerlendirme sonuçları alan cinsinden gösterilmiştir.

Çizelge 4.6 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve meşcere haritasına ait vektörleştirme sonuçlarının alan cinsinden değerlendirilmesi ve karşılaştırılması.

Sınıf \ Veri	Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü	1/25000 Ölçekli Meşcere Haritası
İbrelili ($Alan - m^2$)	5416952.35 (%100)	6529591.94 (%120)
Yapraklı ($Alan - m^2$)	2225442.03 (%100)	1791739.26 (%81)
Tarım Alanı ($Alan - m^2$)	805756.80 (%100)	878141.14 (%109)
Açık Alan ($Alan - m^2$)	1711143.21 (%100)	298091.70 (%17)

Çizelge 4.6’da gösterilen sonuçlara göre ibrelili sınıfı için %120, yapraklı sınıfı %81, tarım alanı %109, açık alan %17 yüzdelerle değerlendirilmiştir. Ormancılık çalışmalarında sıklıkla kullanılan meşcere haritaları genel olarak büyük ormanlık alanları ifade etmelerinden dolayı 3000 metrekarenin altında kalan küçük alanları göstermezler. Yukarıdaki şekillerde de görüldüğü gibi sınıf türlerine ait bazı alanlar meşcere haritasında yansıtılmamaktadır. Bina sınıfı için karşılaştırmalı yüzdeler hesaplanmamıştır. Buna neden olarak; Şekil 4.39’da görüldüğü gibi elle vektörleştirilmiş uydu görüntüsünde her bir bina kendi içinde vektörleştirilirken, meşcere haritasında binalar ve yollar birleştirilerek yerleşim alanı olarak vektörleştirilmesi gösterilmiştir. Buda aralarında metrekare bazında büyük bir farklılığa neden olmuştur. İbrelili sınıfına görsel olarak bakıldığında elle vektörleştirilmiş uydu görüntüsüne göre daha fazla alanı kapladığı görülmektedir.


İki veri arasında geometrik doğruluklarının farklılığından kaynaklanan konumsal hatalar da alan farkına neden olmaktadır. Şekil 4.35’te, meşcere haritasında ibrelili sınıfına ait orman yer örtüsünün fazla alana sahip olması, orman içi açıklıkların, bazı orman yollarının küçük alanlara sahip olduklarından dolayı bu sınıf türüne dahil edilmiş olması bu duruma neden olarak gösterilebilir. Yapraklı sınıfı ile karşılaştırma da elle vektörleştirilmiş uydu görüntüsüne göre daha az alanı kapladığı görülmekte, bunun nedeni olarak Şekil 4.36’daki tarım alanı, bina sınıfları arasında kalan ya da orman içlerindeki açıklıklarda oluşmuş yapraklı ağaç türlerinin meşcere haritasında yer alamaması olarak gösterilebilir. Şekil 4.37’deki tarım alanı için görsel değerlendirme yapıldığında sayısal sonuçlarda da olduğu gibi gerçeğe en yakın sonucu veren sınıf olmuştur. Meşcere haritasının mevcut tarım alanlarını genel olarak göstermesi bu olumlu sonuca en büyük etken olarak gösterilebilir. Geometrik kayıplık, zamansal farktan kaynaklı

değişimlerde sonuçlar arasındaki farka sebep olarak gösterilebilir. Şekil 4.38'deki açık alan sınıfı bu değerlendirme için çalışılan alanda en kötü sonuçları veren sınıf olmuştur. Meşcere haritalarının 3000 metrekarenin altındaki alanları göstermemesi, bu sınıf türüne ait ormanlık alanlar içinde kalan küçük açıklıkları, orman yolları, köy içi yollarını bulundurmaması en büyük sebep olmuştur. Başka bir dezavantaj ise meşcere haritasının yapım tarihi ile uydu görüntüsünün alım tarihi arasındaki zamansal farka bağlı olarak arazi yüzeyinde meydana gelen değişimler olmuştur. Ormanlık alanların çoğalması ya da kesim gibi sebeplerden azalması, yeni köy içi yolların açılması, açık alanlarda meydana gelen değişimler, tarım alanlarının sınır değişimleri gibi nedenlerde elle vektörleştirilmiş uydu görüntüsü ile alan cinsinden değişime yol açan sebeplerden olmuştur.


Sonuçlara genel olarak bakıldığında sayısal değerlerin elle vektörleştirilmiş uydu görüntüsü ile uyumlu olması görsel olarak da sağlanmalıdır. Karşılaştırmada yaşanan sorun meşcere haritasının 3000 metrekare altında kalan alanları göstermeden başka sınıflara dahil etmesi olmuştur. Kullanılan uydu görüntüsü ile 1/25000 ölçekli meşcere haritası arasındaki geometrik doğruluğun farklı olmasından dolayı da mevcut kayıklık analiz sonuçlarını etkilemiştir. Meşcere haritasının yapım tarihi ile uydu görüntüsünün alım tarihi arasındaki zamansal farktan kaynaklı değişimlerde göz önünde bulundurulduğunda, elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün baz alınarak yapıldığı bu değerlendirme sonucu için meşcere haritasına ait bu olumsuzluklar sonuçlara da yansımıştır. 1/25000 ölçekli meşcere haritasının arazi yapısını yüksek hassasiyetle ve doğru örtü tipiyle tanımlamadığı için özellikle yüksek doğruluk istenilen çalışmalar için altlık olarak kullanılmaması gerektiği sonucuna varılmıştır.

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

Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü elle vektörleştirilerek nesne-tabanlı sınıflandırma sonucunda oluşan vektör veri ile tüm sınıflar için aşağıdaki şekillerdeki gibi görsel olarak değerlendirilmiş ve Çizelge 4.7 'de sayısal olarak analizleri yapılmıştır.



(a)



(b)

a) Kırmızı boyalı alanlar elle vektörleştirilmiş GeoEye-1 uydu görüntüsünü temsil ederek nesne-tabanlı sınıflandırma sonuçlarının vektör verisi üzerindeki durumunu, b) Mavi boyalı alanlar nesne-tabanlı sınıflandırma sonuçlarının vektör verisini temsil ederek elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün üzerindeki durumunu göstermektedir.




— Elle vektörleştirilmiş
GeoEye-1 uydu görüntüsü


— Nesne-tabanlı
sınıflandırma sonuçları

c) Geoeeye-1 uydu görüntüsü üzerinde, görüntünün elle vektörleştirme sonuçlarının ve nesne-tabanlı sınıflandırma sonuçlarının vektör verisiyle karşılaştırılması.

Şekil 4.40 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırma sonuçları üzerinden “İbrelî” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.




(a)



(b)

a) Kırmızı boyalı alanlar elle vektörleştirilmiş GeoEye-1 uydu görüntüsünü temsil ederek nesne-tabanlı sınıflandırma sonuçlarının vektör verisi üzerindeki durumunu, b) Mavi boyalı alanlar nesne-tabanlı sınıflandırma sonuçlarının vektör verisini temsil ederek elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün üzerindeki durumunu göstermektedir.



— Elle vektörleştirilmiş
GeoEye-1 uydu görüntüsü


— Nesne-tabanlı
sınıflandırma sonuçları

c) Geoeye-1 uydu görüntüsü üzerinde, görüntünün elle vektörleştirme sonuçlarının ve nesne-tabanlı sınıflandırma sonuçlarının vektör verisiyle karşılaştırılması.

Şekil 4.41 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Yapraklı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.




(a)



(b)

a) Kırmızı boyalı alanlar elle vektörleştirilmiş GeoEye-1 uydu görüntüsünü temsil ederek nesne-tabanlı sınıflandırma sonuçlarının vektör verisi üzerindeki durumunu, b) Mavi boyalı alanlar nesne-tabanlı sınıflandırma sonuçlarının vektör verisini temsil ederek elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün üzerindeki durumunu göstermektedir.

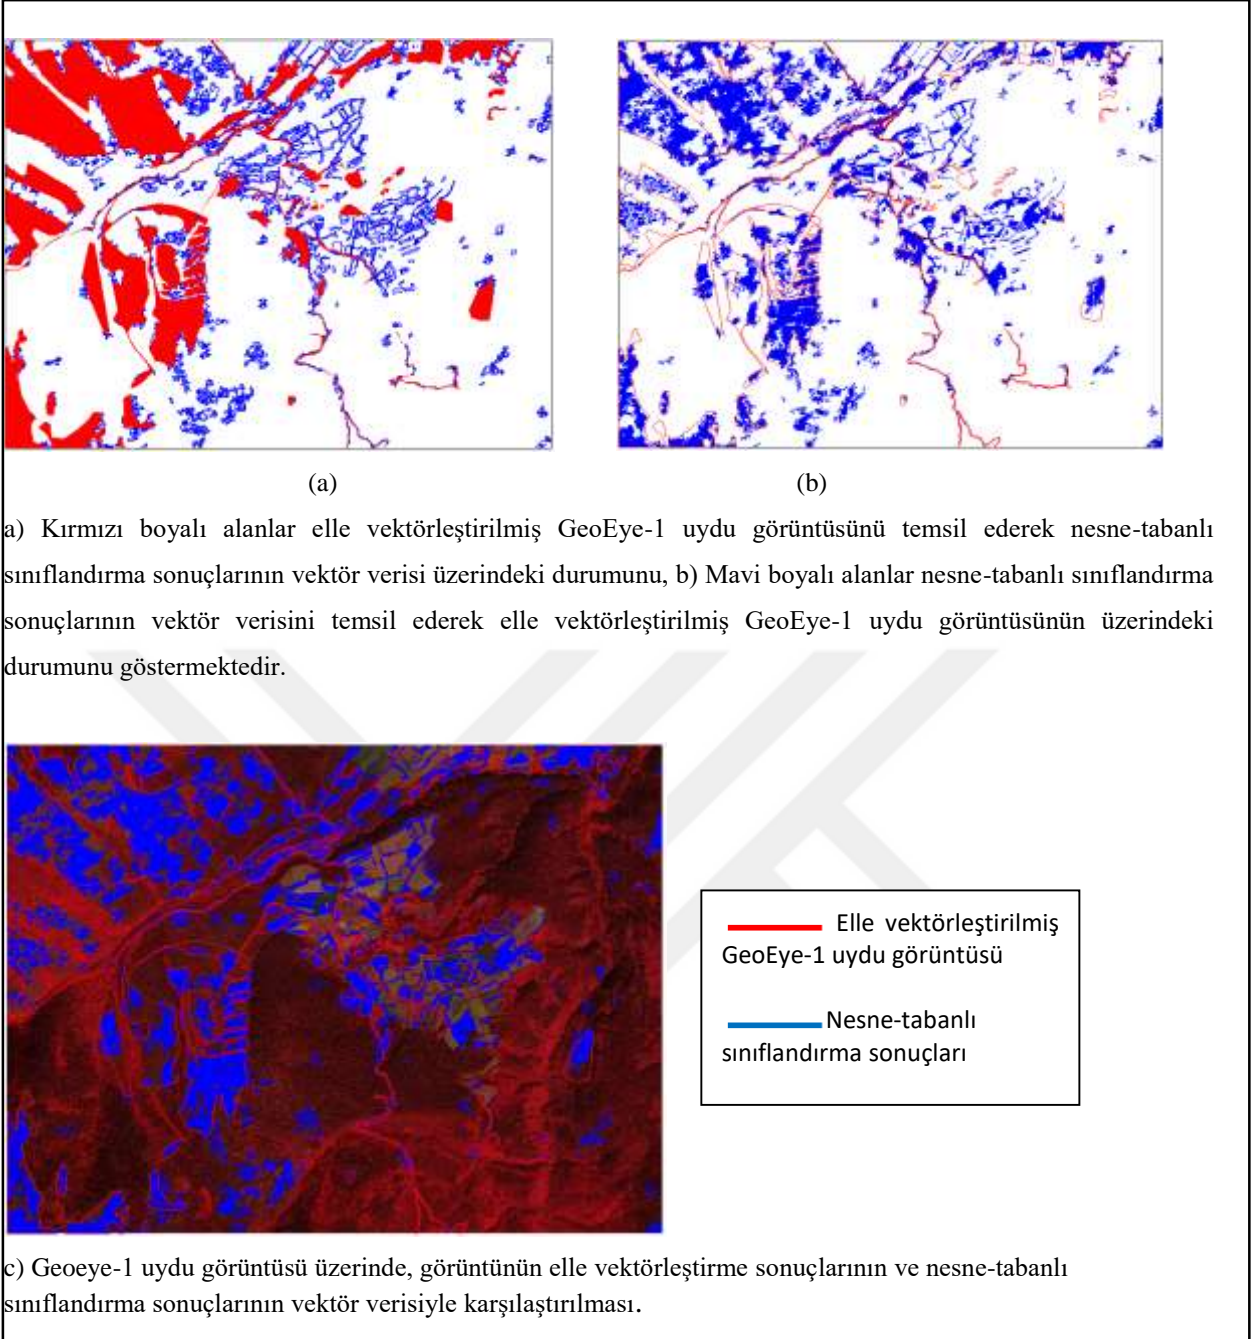


— Elle vektörleştirilmiş
GeoEye-1 uydu görüntüsü

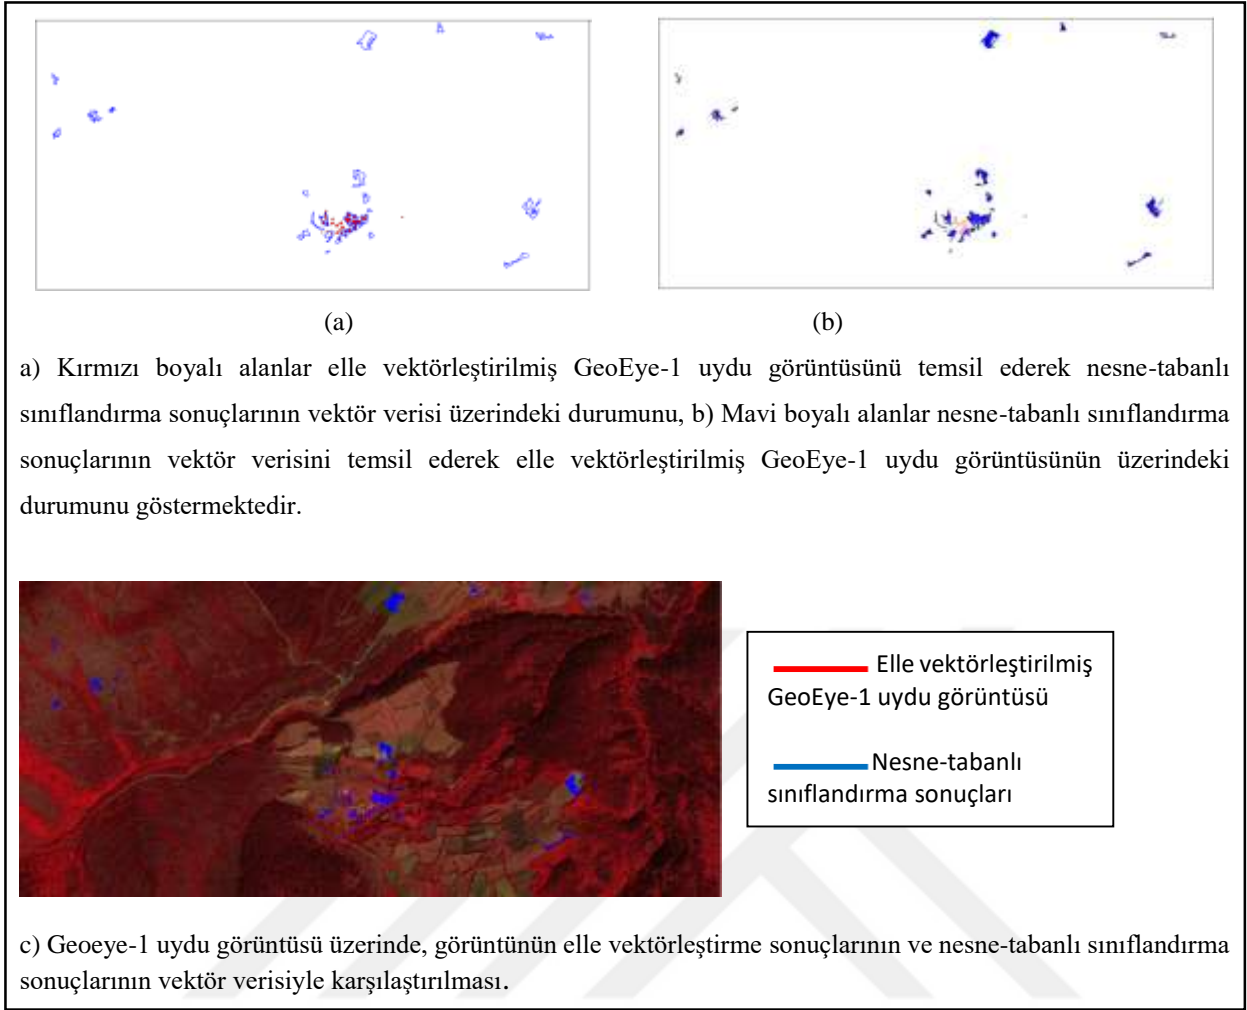
— Nesne-tabanlı
sınıflandırma sonuçları

c) Geoeye-1 uydu görüntüsü üzerinde, görüntünün elle vektörleştirme sonuçlarının ve nesne-tabanlı sınıflandırma sonuçlarının vektör verisiyle karşılaştırılması.

Şekil 4.42 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Tarım alanı” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



Şekil 4.43 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Açık alan” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.



Şekil 4.44 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırma sonuçları üzerinden “Bina” sınıfına ait vektörleştirme sonuçları için CBS tabanlı analizler.

Çizelge 4.7’de elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün ve nesne-tabanlı sınıflandırma sonuçlarının, NetCAD v5.2 yazılımı kullanılarak tüm sınıflar için, uydu görüntüsü baz alınarak yapılan sayısal değerlendirme alan cinsinden gösterilmiştir.

Çizelge 4.7 Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ve nesne-tabanlı sınıflandırmaya ait vektörleştirme sonuçlarının alan cinsinden değerlendirilmesi ve karşılaştırılması.

Sınıf \ Veri	Elle Vektörleştirilmiş GeoEye-1 Uydu Görüntüsü	Nesne-Tabanlı Sınıflandırma
İbrelili ($Alan - m^2$)	5416952.35 (% 100)	4487888.00 (%83)
Yapraklı ($Alan - m^2$)	2225442.03 (% 100)	2682672.00 (% 121)
Tarım Alanı ($Alan - m^2$)	805756.80 (% 100)	702576.00 (%87)
Açık Alan ($Alan - m^2$)	1711143.21 (% 100)	1630268.00 (%95)
Bina ($Alan - m^2$)	5787.63	29728.00

Çizelge 4.7'ye bakıldığında ibrelili sınıfı %83, yapraklı sınıfı %121, tarım alan sınıfı %87, açık alan sınıfı %95 ve bina sınıfı ise olağanın dışında yüksek bir yüzdellik değer almıştır. Görsellerde gördüğümüz sonuçları sayısal değerlendirme ile analiz edersek ibrelili sınıfı nesne-tabanlı sınıflandırma sonuçlarında, elle vektörleştirilen uydu görüntüsüne göre yaklaşık 1 hektarlık alanı yansıtmamaktadır. Yapraklı sınıfı ise bu durumun tam tersi olarak yaklaşık yarım hektarlık fazla bir alanı kaplamaktadır. Nesne-tabanlı sınıflandırma sonuçlarını elde ederken yukarıdaki başlıklarda belirttiğimiz gibi segmentasyon parametreleri belirtilerek yapılmış ve en ufak detayın doğru sınıflandırılması için her bir parametrenin alabileceği en küçük değerler seçilmiştir. Çalışma alanı olarak geniş yer kaplayan ormanlık bir bölge seçilmesine karşılık, doğru sınıflandırma sonucunda yüksek doğruluk ile sonuçlar elde edilmiştir. İbrelili sınıfının elle vektörleştirilmiş uydu görüntüsüne göre düşük değerli çıkması Şekil 4.40'da görüldüğü gibi sınıflandırma sonucunda benzer spektral yansımaya sahip bazı tarım alanı ve yapraklı sınıflarına ait bölgelerde ayırt edilememe durumu ile ifade edilebilir. Uydu görüntüsü vektörel veri olarak sayısallaştırılırken piksel bazında düşünülmeden, gözle ayırt edilebilen dış sınırlardan geçirilmiştir. Bu durum nesne-tabanlı sınıflandırma ile karşılaştırma sonuçlarını görsel ve sayısal olarak bütün sınıflar için etkilemiştir. Yapraklı sınıfının yüksek değere sahip olması nesne-tabanlı sınıflandırma da piksellerin oluşturduğu küçük nesnelerin, sayısallaştırma yaparken kullanıcı tarafından olabilecek sınıfa atanmaması durumu olarak da gösterilir. Bir başka neden olarak da ibrelili sınıfını olumsuz olarak etkileyen durum Şekil 4.41'de görüldüğü gibi yapraklı sınıfı içinde mevcuttur. Benzer spektral yansıma değerlerine sahip sınıf türleri ayırt edilemeyerek yapraklı sınıfına atanması da bu sonuca örnek olarak gösterilebilir. Tarım alanı sınıfı da yukarıda anlatılan benzer durumları ile bazı bölgelerde gerçek arazi yüzeyini yansıtmadan yanlış sonuçlar vermiştir. Şekil 4.42'ye

bakıldığında hem iki vektör sonucunun üst üste getirilmesi hem de raster veri üzerinde bakıldığında olması gereken yerde başka bir sınıf atanırken, açık alan ve orman yer örtü tipine ait yerlerde tarım alanı sınıfının atandığı görülmektedir. Açık alan sınıfı hem Şekil 4.43'teki görselde hem de sayısal değerlendirme sonuçlarına göre olumlu ve benzer sonuçlar vermiştir. Ancak bazı alanlarda başka sınıflar ile spektral benzerlik göstererek elle vektörleştirilmiş uydu görüntüsü ile uyumsuz olmuştur. Bina sınıfı için görsel ve sayısal değerlendirmeler arasında büyük farklar olduğu görülmektedir. Bu fark nesne-tabanlı sınıflandırma sonucunda Şekil 4.44'te görüldüğü gibi elle vektörleştirilmiş uydu görüntüsünde olması gereken bölgelerin dışında kalan alanlarda sınıflandırılarak yanlış sonuçlar vermiş olmasından kaynaklanmış ve bu da sayısal değerlendirme sonuçlarına yansımıştır.

4.6.3. CBS Ortamındaki Karşılaştırılmalı Analiz Sonuçlarının İrdelenmesi

Çalışmada kullanılan 2011 yılına ait yüksek çözünürlüklü GeoEye-1 uydu görüntüsü elle vektörleştirilmiş ve bu veri baz alınarak ormancılık çalışmalarında sıkça kullanılan arazi yapısını fazla detaylandırmadan genel hatlarıyla yansıtan büyük ölçekli meşcere haritası ve nesne-tabanlı sınıflandırma sonuçları vektörleştirilerek, CBS yazılımı ile karşılaştırılmıştır. GeoEye-1 uydu görüntüsünün geometrik düzeltilmesi yapılırken kullanılan SYM için görüntü üzerinden 32 YKN seçilerek yapılmış ve 8 cm doğruluk ile koordinatlı görüntü elde edilmiştir. Elde edilen doğruluk çalışma için yüksek doğruluk sağlamış ve kullanıma hazır hale gelmiştir. Bu görüntü üzerinden karşılaştırmalar yapmak için hem vektörleştirme işlemi yapılmış olup hem de nesne- tabanlı sınıflandırma görüntü verisi elde edilmiştir.

İlk olarak, karşılaştırma için baz alınmış olan elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ile meşcere haritası için yapılmıştır. Meşcere haritası çalışılan bölgeye ait Kastamonu Orman Bölge Müdürlüğünden temin edilmiş olup, tescilli bir harita olduğu için geometrik doğruluğu değerlendirilmeden kullanılmıştır. 1/25000 ölçekli meşcere haritası yüksek geometrik doğruluğa sahip değildir. Ormancılık çalışmalarında çok geniş ormanlık alanları yansıttığı için fazla detay buldurmeyen haritalardır. Yüksek çözünürlüklü GeoEye-1 uydu görüntüsü ile CBS yazılımı altında karşılaştırıldığında aralarında geometrik doğruluk farkından dolayı kayıklık olduğu görülmüş ve aynı dış sınır içerisinde değerlendirilen bu alanlar için kayıklığın olumsuz sonuçların alınmasına neden olmuştur. Bir başka dezavantaj, meşcere haritalarının 3000 metrekare altında kalan detayları içerisinde buldurmamasından kaynaklı hataların oluşmasıdır. Çalışma alanında özellikle açık alan sınıfının büyük bir kısmı meşcere haritasında

yer almamaktadır. Meşcere haritası ile uydu görüntüsü arasındaki zamansal farktan kaynaklı sınıf türlerindeki değişim ve sınıf türlerinin kabaca haritalandırılması da bütün sınıfların sonuç doğruluklarını karşılaştırmalı analizde etkilemiştir.

İkinci karşılaştırma baz alınmış olan elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ile nesne-tabanlı sınıflandırma arasında yapılmıştır. Aynı görüntü üzerinde çalışıldığı için meşcere haritasında olduğu gibi geometrik kayıklık yaşanmamış ve sonuçlar daha gerçeğe yakın olarak alınmıştır. Görsel olarak şekillere bakıldığında karşılaştırmalar için baz alınan elle vektörleştirilmiş GeoEye-1 uydu görüntüsü sayısallaştırılırken gözle görülebilen her detay vektörleştirilmiştir. Nesne-tabanlı sınıflandırma ile karşılaştırıldığında, sınıflandırma sonucu olarak bazı sınıfların benzer spektral yansıma değerlerine sahip olmaları ve ayırt edilememeleri olumsuz durum yaratmış olsa da, doğru segmentasyon parametresiyle sınıflandırmanın yapılması çoğu yerde en küçük alanların bile doğru yansıtıldığı sonucuna vermiştir. Burada elle vektörleştirilen uydu verisi ile uyumsuz çıkan alanlar, yukarıda anlatıldığı gibi nesne-tabanlı sınıflandırma da hem yanlış sınıflara atanması hem de gözle ayırt edilemeyen ya da küçük nesnelerin bile yazılım tarafından seçilerek sınıflara atanmış olması farkın nedeni olarak gösterilebilir.

Çizelge 4.8 1/25000 ölçekli meşcere haritası ve nesne-tabanlı sınıflandırma sonuçlarının elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ile karşılaştırılması.

Veri Sınıf	Elle Vektörleştirilmiş GeoEye-1 Görüntüsü	Nesne- Sınıflandırma Tabanlı	1/25000 Ölçekli Meşcere Haritası
İbrelili ($Alan - m^2$)	5416952.35 (%100)	4487888.00 (%83)	6529591.94 (%120)
Yapraklı ($Alan - m^2$)	2225442.03 (%100)	2682672.00 (%121)	1791739.26 (%81)
Tarım Alanı ($Alan - m^2$)	805756.80 (%100)	702576.00 (%87)	878141.14 (%109)
Açık Alan ($Alan - m^2$)	1711143.21 (%100)	1630268.00 (%95)	298091.70 (%17)
Bina ($Alan - m^2$)	5787.63	29728.00	43637.39

Çizelge 4.8'e bakıldığında her iki vektör verinin, elle vektörleştirilmiş vektör veri ile alan cinsinden karşılaştırılması görülmektedir. Her iki karşılaştırmada çıkan olumsuzlukların nedeni farklı da olsa metrekare bazında hesap yapıldığında sonuçlar ibrelili, yapraklı ve tarım alanı sınıflarında birbirlerine benzer ve yaklaşık değerler almıştır. En büyük farkın açık alan sınıfında olduğu görülmektedir. Bu fark, meşcere haritasında küçük detayların gösterilmeyip birçok orman, köy yolları ve orman içi açıklık gibi alanları bulundurmamasından kaynaklanmaktadır.


Bu çalışmada 1/25000 ölçekli meşcere haritası ile yapılan karşılaştırma sonucunda yüksek ve olumlu yüzdelik değerler elde edilmiş olsa da, karşılaştırmalarda baz alınan elle vektörleştirilmiş GeoEye-1 uydu görüntüsü ile geometrik doğruluklarının farklı olması, düşük hassasiyetli bir harita olması, aralarındaki zamansal farktan kaynaklı arazi örtü tipi değişimi ve küçük alanlar için hassas üretim yapılmadan sınıf türlerinin kabaca ayrılması, çalışılan bölgede her alan için başarılı değerlerin elde edilmesini sağlamamaktadır. Nesne-tabanlı sınıflandırma sonuçlarında alınan sayısal değerler ile şekillerdeki görseller genel olarak uyumlu oldukları ve aynı geometrik doğruluğa sahip görüntü üzerinden çalışıldıkları için başarı değerleri gerçeğe yakın olarak kabul edilmiştir.

4.7. SONUÇLARIN ARAZİ VERİLERİ İLE DEĞERLENDİRİLMESİ

Kastamonu Orman Bölge Müdürlüğü, Merkez Orman İşletme Şefliğine ait çalışma alanında elle vektörleştirilmiş uydu görüntüsü, 1/25000 ölçekli meşcere haritası, nesne-tabanlı ve piksel-tabanlı sayısallaştırma sonuçlarının araziden alınan kontrol noktaları ile değerlendirilmesi yapılmıştır. 12X12 km'lik çalışma alanı içinde belirlenen beş sınıf tipine ait her sınıftan 30 adet koordinatlı kontrol noktası alınmış ve toplamda 150 adet nokta ile değerlendirme yapılmıştır (Şekil 4.45).


Ölçme yöntemi olarak yüksek doğruluklu konum bilgisi verdiği için Global Navigation Satellite System (GNSS) seçilmiştir. GNSS, düzenli olarak kodlanmış bilgi yollayan bir uydu ağıdır. TÜBİTAK tarafından geliştirilen gerçek zamanlı konum bilgisi için sabit GNSS istasyonlarından ve kontrol merkezlerinden oluşan yer merkezli konumlama sistemi olan, ülke temel ağı olarak kabul edilmiş TUSAGA-AKTİF/CORS-TR ağı kullanılmıştır. Yörünge sürekli olarak dönen 24 uydudan oluşur ve uydularla nesne arasındaki mesafeyi ölçerek dünya üzerinden kesin konum bilgisi elde etmeyi mümkün kılar. Uyduların yaydığı çok düşük güçlü radyo sinyallerini yeryüzündeki GNSS alıcısı ile alır. GNSS'nin zayıf yönü ise, alıcı antenin açık gökyüzünü görmesi gerektiğidir. Bu gibi gökyüzünün yeteri kadar görülmediği durumlarda yani yeterli sayıdaki ortak uyduya (en az 4 uydu) gözlem yapılamadığında (float solution) dm doğruluğunda bir çözüm elde edilmektedir. Bu yöntemin kullanım şekli diferansiyel GNSS (DGNSS) 'tir. DGNSS yönteminde sadece kod ölçülerinin kullanılması, elde edilen doğruluğun 1-2 metre hassasiyetinde olmasına da neden olmaktadır (Kahveci vd. 2011).

Çalışma alanı yoğun olarak ormanlık alanı kapladığı için ve ağaçların yoğunluğundan dolayı çoğu alanda GNSS'nin yeterli uydu görememesi “float solution” durumunda yani DGNSS yöntemi ile ölçümlerin yapılmasına karar verilmiştir. Çalışılan raster ve vektör verilerin karşılıklı değerlendirilmeleri için aynı datum ve projeksiyon parametrelerine sahip olmaları gerekmektedir. Datum herhangi bir noktanın yatay ve düşey konumunu belirlemek için alınan referans yüzeyidir. Türkiye’de kullanılan datuamlar Avrupa’nın kullandığı EUROPEAN 1950 (ED50), GRS80 elipsoidini referans olarak kabul eden International Terrestrial Reference Frame (ITRF96), uzaktan algılama çalışmalarında kullanılan uydu görüntülerinin ve Google Earth yazılımının da kullandığı, GNSS alıcılarının temel hesap yüzeyi olarak kabul ettikleri 1984 yılından beri uygulamada olan World Geodetic System (WGS84)’tür. Çalışmada araziden alınan GNSS verileri ITRF96 datumunda iken, uydu görüntüsü ve meşcere haritası WGS84 datum parametresine sahiptir. Diğer proje parametresi olan projeksiyon ise fiziksel yeryüzünün geometrik bir yüzey üzerine iz düşürülmesidir. Uygulamada kullanılan projeksiyon parametreleri Universal Transvers Merkator (UTM) 3° ve UTM 6°’dir. UTM American Military Service tarafından üretilmiş, TM’i kullanan bir projeksiyondur. GNSS verilerine ait projeksiyon parametresi UTM 3° iken uydu görüntüsü ve meşcere haritasına ait projeksiyon parametresi UTM 6°’dir.




Şekil 4.45 Araziden alınan noktaların uydu görüntüsü üzerindeki dağılımı.


GNSS ile alınan koordinat veri uzantısı değerlendirme için kullanılan NetCAD V5.2 yazılımı uzantısı ile aynı değildir. Bilgisayar ortamına aktarılan GNSS verileri Windows Mobile yazılımı ile NetCAD yazılımının açabileceği “*.ncn” uzantılı dosyası haline getirilmiştir. Uzantısı değiştirilen dosyanın datumu ITRF96, projeksiyonu ise UTM 3° ; kullanılan uydu görüntüsü ve meşcere haritasının datumu ise WGS84, projeksiyonu da UTM 6° 'dir. 1/25000 ölçekli meşcere haritası Orman Bölge Müdürlüğü arşivinde ED50 datumu ve UTM 6° projeksiyon parametresi ile tescil edilmiştir. Uzaktan algılama çalışmalarında kullanılan uydu görüntüleri WGS84 ve UTM 6° proje parametrelerine sahip oldukları için gerekli dönüşüm parametreleri hazırlanmış ve meşcere haritasının datum, projeksiyon parametreleri WGS84-UTM 6° olarak hazır hale getirilmiştir. Araziden DGNSS ölçme yöntemiyle alınan noktaların proje parametreleri ITRF96-UTM 3° olduğu için uydu görüntüsü ve meşcere haritalarının sahip oldukları WGS84-UTM 3° proje parametrelerine dönüştürülmüşlerdir. Dönüşüm işlemi NetCAD v5.2 yazılımı ile kendi bünyesinde bulundurduğu dönüşüm parametreleri kullanılarak yapılmıştır. Bu şekilde bütün raster ve vektör veriler aynı proje parametrelerine getirilerek arazi ölçümlerinde her bir sınıftan alınan 30 adet koordinat verisi diğer veriler üzerine atılmış ve karşılık geldikleri sınıflara göre değerlendirilmeleri nokta bazında görsel ve sayısal olarak yapılmıştır. Araziden alınan koordinatlar bu kısımda baz alınmış olup elle vektörleştirilmiş uydu görüntüsü, meşcere haritası, nesne-tabanlı ve piksel- tabanlı sınıflandırma sonuçları ile karşılaştırılmaları aşağıdaki Şekil 4.46, Şekil 4.47, Şekil 4.48, Şekil 4.49 ve Şekil 4.50'da gösterilen örnek görseller ve çizelgelerle gösterilmiştir.




Şekil 4.46 İbrelî sınıf türüne ait arazi noktalarının elle vektörleştirilmiş uydu görüntüsü ile değerlendirilmesi.




Şekil 4.47 Yapraklı sınıf türüne ait arazi noktalarının nesne-tabanlı sınıflandırma sonucu ile değerlendirilmesi.



Şekil 4.48 Tarım alanı sınıf türüne ait arazi noktalarının 1/25000 ölçekli meşçere haritası ile değerlendirilmesi.



Şekil 4.49 Açık alan sınıf türüne ait arazi noktalarının piksel-tabanlı sınıflandırma sonucu ile değerlendirilmesi.




Şekil 4.50 Bina sınıf türüne ait arazi noktalarının nesne-tabanlı sınıflandırma sonucu ile değerlendirilmesi.

Görsel olarak değerlendirme yapıldığında 28-29-30 Haziran 2017 tarihlerinde çıkılan araziden alınmış koordinatlı noktalar elle vektörleştirilmiş uydu görüntüsü, nesne-tabanlı ve piksel-tabanlı sınıflandırma sonuçları ve 1/25000 ölçekli meşcere haritası üzerine atıldığında birbiriyle uyuşmayan sınıflar daire içine alınarak gösterilmiştir. Araziden DGNSS yöntemiyle alınan koordinatlar yoğun ormanlık alan içerisinde yeteri kadar uydudan sinyal alınmadığı için 1-2 metre hassasiyetle ölçülmüştür. Ölçülen noktaların koordinat sistemi UTM 3° -ITRF96 proje parametrelerine sahipken, değerlendirmesi yapılacak veriler UTM 6° -WGS84 proje parametrelerine sahiptir. NetCAD v5.2 yazılımının kendi içerisinde bulundurduğu dönüşüm parametresi kullanılarak arazi verileri ile diğer veriler aynı parametre değerlerine getirilerek değerlendirmeye hazır hale getirilmiştir. Dönüşüm yapılırken yazılım tarafından hazırlanan dönüşüm parametreleri bilgilerinin doğruluğuna göre az da olsa bir doğruluk kaybı meydana gelmektedir. Yapılan ölçme yönteminin hassasiyeti ve dönüşümden kaynaklı hatalar değerlendirme sonuçlarını etkileyen sebeplerden olmuştur.

Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü 3.11.2011 tarihinde alınmıştır. Aradan geçen zaman, sınıf türlerinde değişime yol açmış ve değerlendirme sonuçlarını olumsuz etkilemiştir. Uydu görüntüsünde mevcut olmayan bazı orman içi açıklıklar oluşurken, bazı açıklıklar orman örtüsüyle kaplanmıştır. Zamansal değişimde orman örtü

tiplerinde yer yer çoğalma gözlemlenirken, bazı alanlarda kesim gibi sebeplerden ötürü azalma meydana geldiği de görülmüştür. Tarım alanlarının sınırlarındaki değişim ve yeni köy içi yolların oluşumu da zamansal değişim sonuçlarına örnektir. Çalışma alanı 12X12 km’lik bir alanı kapladığı için arazide alım yapılan alanların dışında kalan kısımlar için 27.07.2016 tarihli Google Earth görüntüsünden de yararlanılmıştır. Şekil 4.51’de Google Earth ve uydu görüntüsü arasındaki görsel farka ait örnekler gösterilmiştir.



Şekil 4.51 Uydu görüntüsünün 27.07.2016 tarihli Google Earth görüntüsü ile arasındaki zamansal değişimi.

Zamansal değişim dışında arazi değerlendirme sonuçlarını etkileyen bir başka olumsuz etmen ise elle vektörleştirilmiş uydu görüntüsünün sayısallaştırılırken piksel boyutunda küçük alanları içeren sınıf türlerinin alınamaması olmuştur. Nesne-tabanlı ve piksel-tabanlı sınıflandırma sonuç doğrulukları ki bu konu ile ilgili sonuçlar üst başlıklarda detaylı bir şekilde belirtilmiştir, 1/25000 ölçekli meşcere haritasında sınıfların kabaca çizilerek üretilmesi, 3000 metrekarenin altında kalan alanların haritada gösterilmemesi gibi sebeplerden dolayı alım yapılan noktalar bazı alanlarda uyumsuz sonuçlar vermiştir. Belirtilen olumsuz sebepler görsel olarak olduğu kadar sayısal olarak da yüzdelik hesaplama sonuçlarını etkilemiştir. Koordinatlı arazi verileri ile diğer verilerin bütün sınıf türleri için değerlendirilmesi ve karşılaştırılması Çizelge 4.9, Çizelge 4.10, Çizelge 4.11, Çizelge 4.12 ve Çizelge 4.13’te gösterilmiştir.

Çizelge 4.9 İbrelî sınıf türünün arazi değerlendirme sonuçları.

SONUÇ	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
NOKTA NO					
1	İBRELİ	×(YAPRAKLI)	✓	✓	✓
2	İBRELİ	✓	✓	✓	×(YAPRAKLI)
3	İBRELİ	✓	✓	✓	✓
4	İBRELİ	✓	✓	✓	✓
5	İBRELİ	✓	✓	✓	✓
6	İBRELİ	✓	×(YAPRAKLI)	✓	×(YAPRAKLI)
7	İBRELİ	✓	✓	✓	✓
8	İBRELİ	✓	×(YAPRAKLI)	✓	✓
9	İBRELİ	✓	✓	✓	✓
10	İBRELİ	✓	✓	✓	✓
11	İBRELİ	✓	×(YAPRAKLI)	✓	✓
12	İBRELİ	✓	✓	✓	✓
13	İBRELİ	✓	×(YAPRAKLI)	✓	✓
14	İBRELİ	✓	✓	✓	✓
15	İBRELİ	✓	✓	✓	✓
16	İBRELİ	✓	✓	✓	✓
17	İBRELİ	×(AÇIK ALAN)	×(AÇIK ALAN)	×(AÇIK ALAN)	✓
18	İBRELİ	✓	✓	✓	✓
19	İBRELİ	✓	✓	✓	✓
20	İBRELİ	✓	✓	✓	✓
21	İBRELİ	✓	✓	✓	×(YAPRAKLI)
22	İBRELİ	✓	✓	✓	✓
23	İBRELİ	✓	✓	✓	✓
24	İBRELİ	✓	✓	✓	✓
25	İBRELİ	×(YAPRAKLI)	✓	✓	✓
26	İBRELİ	✓	✓	✓	✓
27	İBRELİ	✓	✓	✓	✓
28	İBRELİ	✓	✓	✓	✓
29	İBRELİ	×(YAPRAKLI)	✓	✓	✓
30	İBRELİ	✓	✓	✓	✓

Çizelge 4.10 Yapraklı sınıf türünün arazi değerlendirme sonuçları.

SONUÇ NOKTA NO	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
31	YAPRAKLI	✘(İBRELİ)	✘(İBRELİ)	✓	✘(İBRELİ)
32	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
33	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
34	YAPRAKLI	✓	✓	✓	✓
35	YAPRAKLI	✓	✓	✓	✓
36	YAPRAKLI	✓	✓	✘(İBRELİ)	✘(İBRELİ)
37	YAPRAKLI	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)
38	YAPRAKLI	✘(İBRELİ)	✓	✘(İBRELİ)	✓
39	YAPRAKLI	✓	✓	✓	✓
40	YAPRAKLI	✓	✓	✓	✓
41	YAPRAKLI	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)
42	YAPRAKLI	✓	✓	✓	✓
43	YAPRAKLI	✓	✓	✓	✓
44	YAPRAKLI	✓	✓	✓	✓
45	YAPRAKLI	✓	✓	✓	✓
46	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
47	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
48	YAPRAKLI	✓	✓	✓	✘(AÇIK ALAN)
49	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
50	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
51	YAPRAKLI	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)
52	YAPRAKLI	✘(İBRELİ)	✓	✓	✘(İBRELİ)
53	YAPRAKLI	✓	✓	✓	✘(İBRELİ)
54	YAPRAKLI	✓	✓	✘(İBRELİ)	✘(İBRELİ)
55	YAPRAKLI	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)	✘(İBRELİ)
56	YAPRAKLI	✘(İBRELİ)	✓	✘(TARIM ALANI)	✘(İBRELİ)
57	YAPRAKLI	✓	✓	✘(İBRELİ)	✓
58	YAPRAKLI	✓	✓	✓	✓
59	YAPRAKLI	✓	✓	✘(AÇIK ALAN)	✓
60	YAPRAKLI	✘(İBRELİ)	✓	✘(İBRELİ)	✘(İBRELİ)

Çizelge 4.11 Tarım alanı sınıf türünün arazi değerlendirme sonuçları.

SONUÇ	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
NOKTA NO					
61	TARIM ALANI	✓	✓	✓	✓
62	TARIM ALANI	✓	✓	✗(AÇIK ALAN)	✓
63	TARIM ALANI	✓	✓	✓	✓
64	TARIM ALANI	✓	✓	✓	✗(İBRELİ)
65	TARIM ALANI	✓	✓	✓	✓
66	TARIM ALANI	✓	✓	✓	✓
67	TARIM ALANI	✓	✓	✓	✓
68	TARIM ALANI	✓	✓	✓	✓
69	TARIM ALANI	✓	✓	✓	✓
70	TARIM ALANI	✓	✗(YAPRAKLI)	✓	✓
71	TARIM ALANI	✓	✓	✓	✓
72	TARIM ALANI	✓	✓	✓	✓
73	TARIM ALANI	✗(İBRELİ)	✗(AÇIK ALAN)	✓	✓
74	TARIM ALANI	✓	✓	✓	✓
75	TARIM ALANI	✓	✓	✓	✓
76	TARIM ALANI	✓	✓	✓	✓
77	TARIM ALANI	✓	✓	✓	✓
78	TARIM ALANI	✓	✓	✓	✓
79	TARIM ALANI	✓	✓	✓	✓
80	TARIM ALANI	✓	✗(AÇIK ALAN)	✓	✓
81	TARIM ALANI	✓	✗(AÇIK ALAN)	✓	✓
82	TARIM ALANI	✓	✗(AÇIK ALAN)	✓	✓
83	TARIM ALANI	✓	✓	✓	✓
84	TARIM ALANI	✓	✓	✓	✓
85	TARIM ALANI	✓	✓	✗(BİNA)	✓
86	TARIM ALANI	✓	✓	✓	✗(İBRELİ)
87	TARIM ALANI	✓	✓	✗(İBRELİ)	✓
88	TARIM ALANI	✓	✓	✓	✓
89	TARIM ALANI	✓	✓	✓	✗(İBRELİ)
90	TARIM ALANI	✓	✓	✗(İBRELİ)	✓

Çizelge 4.12 Açık alan sınıf türünün arazi değerlendirme sonuçları.

SONUÇ	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
NOKTA NO					
91	AÇIK ALAN	✓	×(TARIM ALANI)	×(TARIM ALANI)	×(YAPRAKLI)
92	AÇIK ALAN	✓	✓	×(TARIM ALANI)	×(TARIM ALANI)
93	AÇIK ALAN	×(İBRELİ)	×(YAPRAKLI)	×(YAPRAKLI)	×(YAPRAKLI)
94	AÇIK ALAN	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)
95	AÇIK ALAN	×(YAPRAKLI)	×(YAPRAKLI)	×(YAPRAKLI)	×(YAPRAKLI)
96	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
97	AÇIK ALAN	✓	×(İBRELİ)	×(TARIM ALANI)	×(İBRELİ)
98	AÇIK ALAN	✓	✓	✓	✓
99	AÇIK ALAN	✓	×(İBRELİ)	✓	✓
100	AÇIK ALAN	×(YAPRAKLI)	✓	×(TARIM ALANI)	✓
101	AÇIK ALAN	✓	✓	✓	✓
102	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
103	AÇIK ALAN	✓	✓	✓	×(YAPRAKLI)
104	AÇIK ALAN	✓	✓	✓	×(YAPRAKLI)
105	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
106	AÇIK ALAN	✓	×(TARIM ALANI)	✓	×(İBRELİ)
107	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
108	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
109	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
110	AÇIK ALAN	✓	×(TARIM ALANI)	×(TARIM ALANI)	×(TARIM ALANI)
111	AÇIK ALAN	✓	✓	✓	✓
112	AÇIK ALAN	✓	×(TARIM ALANI)	✓	✓
113	AÇIK ALAN	✓	✓	✓	✓
114	AÇIK ALAN	✓	✓	✓	×(İBRELİ)
115	AÇIK ALAN	×(İBRELİ)	×(YAPRAKLI)	×(TARIM ALANI)	×(İBRELİ)
116	AÇIK ALAN	✓	✓	×(TARIM ALANI)	×(İBRELİ)
117	AÇIK ALAN	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)
118	AÇIK ALAN	×(İBRELİ)	×(YAPRAKLI)	×(TARIM ALANI)	YAPRAKLI
119	AÇIK ALAN	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)	×(İBRELİ)
120	AÇIK ALAN	×(İBRELİ)	×(YAPRAKLI)	×(YAPRAKLI)	×(YAPRAKLI)

Çizelge 4.13 Bina sınıf türünün arazi değerlendirme sonuçları.

SONUÇ	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
NOKTA NO					
121	BİNA	✓	✓	×(AÇIK ALAN)	✓
122	BİNA	✓	✓	✓	✓
123	BİNA	✓	✓	×(TARIM ALANI)	✓
124	BİNA	×(TARIM ALANI)	✓	×(AÇIK ALAN)	✓
125	BİNA	✓	×(AÇIK ALAN)	×(AÇIK ALAN)	✓
126	BİNA	✓	✓	✓	✓
127	BİNA	✓	×(TARIM ALANI)	✓	✓
128	BİNA	×(AÇIK ALAN)	×(TARIM ALANI)	×(AÇIK ALAN)	×(TARIM ALANI)
129	BİNA	×(AÇIK ALAN)	×(TARIM ALANI)	✓	✓
130	BİNA	✓	✓	✓	✓
131	BİNA	✓	✓	✓	✓
132	BİNA	✓	✓	×(TARIM ALANI)	✓
133	BİNA	TARIM ALANI	✓	✓	✓
134	BİNA	✓	✓	×(TARIM ALANI)	✓
135	BİNA	✓	×(TARIM ALANI)	✓	✓
136	BİNA	✓	×(TARIM ALANI)	×(TARIM ALANI)	✓
137	BİNA	✓	×(TARIM ALANI)	✓	✓
138	BİNA	×(AÇIK ALAN)	×(TARIM ALANI)	×(AÇIK ALAN)	✓
139	BİNA	✓	✓	×(TARIM ALANI)	✓
140	BİNA	✓	✓	✓	✓
141	BİNA	✓	✓	✓	✓
142	BİNA	✓	✓	✓	✓
143	BİNA	✓	✓	×(TARIM ALANI)	✓
144	BİNA	×(AÇIK ALAN)	×(AÇIK ALAN)	×(AÇIK ALAN)	✓
145	BİNA	✓	×(TARIM ALANI)	×(TARIM ALANI)	×(TARIM ALANI)
146	BİNA	✓	✓	×(TARIM ALANI)	✓
147	BİNA	×(TARIM ALANI)	×(TARIM ALANI)	×(TARIM ALANI)	×(TARIM ALANI)
148	BİNA	✓	✓	×(TARIM ALANI)	✓
149	BİNA	×(TARIM ALANI)	✓	×(TARIM ALANI)	✓
150	BİNA	✓	✓	×(TARIM ALANI)	✓

Çizelge 4.14 Tüm sınıf türlerinin arazi değerlendirme sonuçlarının karşılaştırılması (%).

SINIF TÜRÜ	ARAZİ SONUÇLARI	ELLE VEKTÖRLEŞTİRİLMİŞ UYDU GÖRÜNTÜSÜ	NESNE-TABANLI SINIFLANDIRMA SONUCU	PİKSEL TABANLI SINIFLANDIRMA SONUCU	1/25000 ÖLÇEKLİ MEŞCERE HARİTASI
İBRELİ (%)	%100	%87	%83	%97	%90
YAPRAKLI(%)	%100	%73	%83	%63	%40
TARIM ALANI(%)	%100	%97	%83	%87	%90
AÇIK ALAN(%)	%100	%70	%53	%53	%23
BİNA(%)	%100	%73	%63	%40	%90

Araziden alınmış her bir sınıfa ait 30 adet koordinatlı noktanın sınıf türleri ile karşılaştırılmaları yukarıdaki çizelgelerde yapılmış olup, yüzdeler olarak değerlendirilmeleri de Çizelge 4.14'te gösterilmiştir. Elle vektörleştirilmiş uydu görüntüsü, arazi sonuçları ile karşılaştırıldığında en yüksek değeri %87 ile ibrelili sınıfı türüne aitken en düşük değer %73 ile bina sınıfına ait olduğu görülmüştür. Nesne-tabanlı sınıflandırma sonucunda %83 ile en yüksek değerleri, ibrelili, yapraklı ve tarım alan sınıfları alırken,%53 ile en düşük değeri açık alan sınıfı almıştır. Pikseltabanlı sınıflandırma sonuçlarından %97 ile en yüksek sonuç ibrelili sınıfına aitken, %40 ile bina sınıfı karşılaştırmada en düşük değeri almıştır. Son olarak 1/25000 ölçekli meşcere haritasının en yüksek sonucu %90 ile ibrelili sınıf türüne aitken en düşük %23 ile açık alan sınıfına ait sonuç vermiştir. Bu sonuç değerlendirmeleri alan bazında değil araziden alınan noktaların sınıf türlerinin diğer verilerdeki sınıf türleriyle nokta bazında karşılaştırılması yapılarak elde edilmiştir. Bu sebeple çalışmada yapılan diğer karşılaştırmalı analizlere göre değerlendirilmeleri ve yorumlanmaları yapılmamıştır.



BÖLÜM 5

SONUÇ VE ÖNERİLER

Çalışmanın amacı ormancılık amaçları doğrultusunda yüksek çözünürlüklü uydu görüntüsü kullanarak piksel ve nesne-tabanlı sınıflandırma sonuçlarının araştırılmasıdır. Araştırma sonrası elde edilen sonuçların birbirlerine göre avantaj ve dezavantajları değerlendirilip amaca uygun sonuç veren yöntem tespit edilmiştir. Elde edilen sonuçlar vektörleştirilmiş GeoEye-1 uydu görüntüsü ve arazi çalışması ile de karşılaştırılmıştır. Meşcere haritalarının revize edilmesi, artan, azalan ya da tahrip olmuş orman alanlarının belirlenmesi, yeni orman örtü tiplerinin haritada güncellenmesi gibi durumlarda ormancılık çalışmalarına altlık oluşturabilecek bir çalışma yapılmıştır.

Bu tez çalışmasında Kastamonu Orman Bölge Müdürlüğü, Merkez İşletme Şefliğine ait 24 320 ha büyüklüğündeki yüksek çözünürlüklü GeoEye-1 uydu görüntüsü üzerinden 12X12 km'lik alan seçilerek uygulamalar yapılmıştır. Kastamonu ili zengin orman örtüsü ile ormancılık çalışmaları için önemli yer tutmaktadır. Seçilen alanda orman örtü tipine ait iki sınıf bulunmaktadır. Görüntünün büyük bir kısmını kaplayan “İbrelili ve Yapraklı” sınıf türlerinin doğrulukları çalışmanın amacını da oluşturmaktadır. Görüntü üzerinde belirlenen diğer üç sınıf “Tarım alanı, Açık alan ve Bina” sınıfları olmuştur. GeoEye-1 uydu görüntüsü 0.41 m pankromatik ve 1.65 m multispektral bantlarla piyasadaki yüksek çözünürlüklü uydu görüntülerinden biridir. Bu görüntünün seçilmesinin nedeni olarak yüksek çözünürlüğe sahip olmasının dışında 700 nm dalga boyundan sonraki kesime ait duyarlı yakın kızıl ötesi banta sahip olmasıdır. Yakın kızıl ötesi bant ağaç türlerinin tespitinde başarılı sonuçlar verdiği için ormanlık alanlarda yapılan çalışmalar da tercih edilmektedir. 03.09.2011 tarihinde alınan GeoEye-1 uydu görüntüsü üzerinden belirlenen beş sınıf tipi kullanılarak piksel ve nesne-tabanlı sınıflandırma sonuçları değerlendirilmiştir. Sınıflandırma sonuçları vektör veri ve arazi çalışmaları ile de analiz edilerek çalışma sonlandırılmıştır. Yapılan uygulamalar hakkında literatür ve sonuç bilgileri çalışma içerisinde detaylı bir şekilde anlatılmış olup aşağıdaki kısımda tezin amacına uygun sonuç ve öneriler belirtilmiştir.

- Çalışma alanına ait kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsünün geometrik düzeltilmesi 32 YKN noktası kullanılarak 8 cm doğrulukla alınmış ve çalışmaya başlanılmıştır. 8 cm doğruluk çalışma için yüksek doğruluk sağlayacağı için yeniden YKN ve SYM verileri üretilmeye gerek duyulmamıştır. Ham görüntü üzerinden çalışmak kullanıcı için arazi denetimi yapmak adına faydalı olsa bile bu gibi durumlarda yüksek doğrulukla ortorektifiye edilmiş görüntülerin kullanımı da kullanıcı için büyük bir avantajdır.
- Yüksek çözünürlüğe sahip uydu görüntüleri ile çalışırken geometrik düzeltme işlemi kadar görüntü zenginleştirme işlemlerinin yapılması da gerekmektedir. Görüntü zenginleştirme pan-sharp adıyla yüksek çözünürlüklü pankromatik görüntü ile düşük çözünürlüklü multispektral görüntünün birleşerek yüksek çözünürlüklü multispektral görüntü oluşturma işlemidir. Çoğunlukla şehir içi uygulamalardaki bina ve yol yapılarının detaylı bir şekilde çıkartılması istenen yüksek doğruluklu çalışmalar için kullanılan bir yöntemdir. Ormanlık alanlarda çalışırken Pan-sharp işlemi görüntü çözünürlüğünü arttırdığı için sınıflandırma doğruluğu olumsuz etkilenmektedir. Buna sebep olarak çözünürlük arttıkça sınıflar içindeki spektral varyansın artması ve arazi tiplerinin spektral olarak karışarak sınıflandırılmış olmaları sonucu ayırt edilememe durumu olarak gösterilebilir. Bu durumdan dolayı tez çalışmasında kullanılan uydu görüntüsü üzerine pan-sharp işlemi uygulanmamıştır.
- Yeşil bitkiler yapılarında bulundukları klorofil sebebiyle yakın kızıl ötesi bölgede az miktarda soğurulmalarından dolayı yansıma değerleri bu bant için büyük ölçüde fazladır. Sonbahar döneminde yeşil bitkilerin klorofil miktarları azalır ve yakın kızıl ötesi bant için yansıma değeri de bununla orantılı olarak azalmaktadır. Çalışmada kullanılan yüksek çözünürlüklü GeoEye-1 uydu görüntüsü 03.09.2011 tarihinde alınmış olup bu tarihte yeşil bitkilerde renksel değişim ve dökülmeler meydana gelse de ibreli ve yapraklı sınıf türünün dahil olduğu orman örtüsü bu tarihte bir değişime uğramadıkları için kızıl ötesi bant için yüksek yansıma değeri ile çalışma yapılmıştır.
- Yüksek çözünürlüklü GeoEye-1 uydu görüntüsü kullanılarak yapılan piksel-tabanlı sınıflandırma sonucu gerçeğe yakın olmayan sonuçlar vermiştir. Görüntünün çözünürlüğünün yüksek olması, sınıflandırma da piksellerden oluşan nesnelere

doğruluğunu büyük ölçüde olumsuz etkilemiştir. Literatürde orta çözünürlüklü uydu görüntüleri için yapılmış piksel-tabanlı sınıflandırma sonuçlarının daha başarılı sonuçlar verdiği görülmüştür.

- Piksel-tabanlı sınıflandırma sadece piksellerin spektral değerlerini göz önünde bulundurarak sonuç elde etmesi, başarıyı olumsuz etkileyen en önemli sebep olarak gösterilebilir. Yakın kızıl ötesi bant ile orman örtü tipine ait ibreli ve yapraklı sınıfları için başarılı sonuçlar üretirken; açık alan, tarım alanı ve bina sınıflarında benzer spektral yansıma değerlerine sahip olmaları yanlış sınıflandırma sonuçları elde edilmesine neden olmuştur. Piksel-tabanlı sınıflandırmada kullanılan uydu görüntüsünde yakın kızıl ötesi bant görüntüde mevcut ise ormancılık çalışmaları için kullanılabilirliği fazla iken özellikle şehir içi uygulamalarında tercih edilmemesi gerektiğine karar verilmiştir.
- Piksel-tabanlı sınıflandırmada belirlenen sınıf tipleri için örnek alanların kullanıcı tarafından seçilmesi ve bu alanların güncellenebilir olması avantaj olarak görülmektedir. Dezavantajı ise hata matrisleri üretilirken yazılım tarafından rastgele kontrol alanlarının seçilmesi olmuştur. Yazılım tarafından yanlış sınıflandırılan alanlar üzerine kontrol noktaları atılması ve değerlendirilmek istenen sınıf türü yeterli nokta sayısı ile değerlendirilememesi özellikle bina sınıfı için olumsuz bir durum olmuştur.
- Nesne-tabanlı sınıflandırma piksel-tabanlı sınıflandırmaya göre çok daha yüksek doğruluklu sonuçlar vermiştir. Bunun en önemli nedeni doğru segmentasyon parametrelerinin seçimi olmuştur. Segmentasyon ve sınıflandırma işlemlerinde segmentlere ait oldukça fazla değişken (seçilen banta ait segmentler içindeki piksellerin ortalama parlaklık değerleri, parlaklık değerlerinin standart sapmaları, obje geometrisi, konumu, objelerin ve/veya sınıfların komşuluk ilişkileri ...) dahil edilebilmektedir. Bu değişkenlerle ilgili çalışmalar için hangilerinin dahil edilebileceği literatürde belirtilmemişken kullanıcı tarafından deneme yanılma yoluyla belirlenmesi gerekmektedir. Segmentasyon aşamasında seçilen ölçek, şekil ve bütünlük parametreleri için de aynı durum geçerlidir. Kullanıcı farklı katmanlara farklı segmentasyon parametrelerini tanımlayarak deneme yanılma yolu ile çalışma için en olumlu sonuca varmalıdır. Bu gibi durumlarda izlenecek sabit bir yöntemin geliştirilmemesi nesne-tabanlı sınıflandırma yöntemi için dezavantaj sayılabilir. Bu dezavantajın yanı sıra yukarıda belirtildiği gibi nesne-tabanlı sınıflandırma işlemleri

kullanılıp piksel-tabanlı sınıflandırmada kullanılmayan mekânsal boyut da kriterler ile uygulamaya dahil edilebilmektedir. Sınıflandırılacak nesnelere ait ölçek, şekil ve bütünlük gibi bazı mekânsal tanımlayıcılar, spektral bilgilerle birlikte sınıflandırma algoritmasına dahil edilerek avantaj sağlamaktadır.

- Nesne-tabanlı sınıflandırmanın piksel-tabanlı sınıflandırmaya göre bir başka üstünlüğü görüntülerde spektral özellikler tanımlanırken tek tek piksel olarak değil, piksellerin oluşturduğu nesnelere spektral özelliklerinin kullanılmasıdır. Ayrıca objeler tekrar şekillendirilebilir ve oluşturulabilir şekilde tanımlanabilmektedirler. Buda piksel-tabanlı sınıflandırmadan farklı olarak spektral, şekilsel ve konumsal bilgilerinde sınıflandırma da kullanılabileceğini gösterir.
- Nesne-tabanlı sınıflandırma sonucunda elde edilen hata matrisine göre genel doğruluk %90.59 kappa değeri ise 0.872'dir. İbrelili ve yapraklı sınıf türleri istenildiği gibi başarılı sonuçlar vermiştir. Tarım alanı, bina ve açık alan sınıfları da %70'in üzerinde doğruluk değeri olarak uzaktan algılama çalışmalarında kabul edilebilir gerçeğe yakın sonuçlar elde edilmiştir. Yanlış sınıflandırmaların nedeni, kullanılan görüntüdeki ayrıntıların durumu, benzer spektral yansıma değerlerine sahip olmalarında dolayı ayırt edilememe durumu, gölge gibi sebepler gösterilebilir. Genel olarak ormancılık çalışmalarında orman yer örtü tipleri ve olabilecek diğer sınıf türleri için başarılı sonuçlar veren nesne-tabanlı sınıflandırma yöntemi amaca uygun olarak kullanılabilir denmektedir.
- Elle vektörleştirilmiş GeoEye-1 uydu görüntüsü, meşcere haritası ve nesne-tabanlı sınıflandırma yaklaşımlarıyla yapılan değerlendirmelerde baz alınan vektör veri olmuştur. Buna sebep olarak, ormancılık disiplinde altlık olarak kullanılan meşcere verilerinin 1/25000 ölçekli olmasından dolayı 0,41 m çözünürlüklü GeoEye-1 uydu görüntü verisinden orman amenajman planı ölçeğine göre daha hassas bir arazi kullanım sınıfları vektörü oluşturulabileceğinden dolayı tercih edilmesi gösterilebilir.
- Yüksek çözünürlüklü GeoEye-1 uydu görüntüsü elle vektörleştirilirken fazla zaman alması açısından ya da kullanıcının yapabileceği hata düşünüldüğünde dezavantaj olsa da; görüntüdeki topoğrafik bozukluklar, gölge gibi sorunlara da müdahale ederek doğru vektörleştirme yapılması avantajdır. Elle vektörleştirilen uydu görüntüsüne baz alınarak yapılan kısımda, 1/25000 ölçekli meşcere haritası ile karşılaştırılırken birçok olumsuz

durum ortaya çıkmıştır. Uydu görüntüsünün alım tarihi ile üretilen meşcere haritasının yapım tarihi arasındaki fark sınıf tiplerindeki değişimi vektör veri üzerinden yapılan alan hesabı ile ortaya koymuştur. Meşcere haritaları düşük konumsal doğruluğa sahip haritalardır. Yüksek doğruluk isteyen çalışmalar için tercih edilmemelidir. Harita üzerindeki alanlar kabaca belirlenmiş olup, 3000 metrekarenin altında kalan yerlerin haritada gösterilmemesi de karşılaştırmadaki diğer bir olumsuzluk olmuştur. En büyük alan farkı bina sınıfındadır. Meşcere haritası üzerinde oldukça küçük ve sınırlı bir alana sahip olduğu için bina bazında değerlendirilmeden bir dış sınır belirlenerek yerleşim alanı olarak gösterilmesi buna en büyük sebeptir. Elle vektörleştirilmiş GeoEye-1 uydu görüntüsünün baz alınarak yapıldığı kısımda, nesne-tabanlı sınıflandırma sonuçları ile vektörel olarak karşılaştırıldığında aynı uydu görüntüsü üzerinden çalışıldığı için zamansal fark durumu yaşanmamıştır. Sınıflandırmadan kaynaklı hatalar ve bazı yerlerde sayısallaştırma işlemi sırasındaki küçük alanların belirtilmemesi gibi durumlardan kaynaklı alan bazında farklılıklar meydana gelmiştir. Bu değerlendirme sonucunda da en büyük alansal fark bina sınıfında yaşanmıştır. Nesnelere olmaları gerektikleri konumlarının dışında benzer yansıma gösterdikleri tarım alanı ve açık alan sınıflarıyla karıştırılarak hatalı sınıflandırılmaları buna en büyük sebep olarak gösterilebilir. Vektörleştirme sonuçlarına bakıldığında 1/25000 ölçekli meşcere haritası özellikle yol ve bina gibi küçük alanları kaplayan nesnelere değerlendirilmesinde altlık olarak kullanılmamalıdır. Ormancılık çalışmalarında sıklıkla kullanılan meşcere haritaları bu değerlendirme sonucunda görsel ve sayısal olarak ormanlık alanlar için olumlu sonuçlar vermesi ormancılık çalışmalarında kullanılabileceğini tekrardan göstermiştir.

- Arazi çalışmasının baz alınarak diğer vektör verileriyle karşılaştırılacağı kısımda, her bir sınıftan seçilen 30 adet kontrol noktası belirlenerek toplamda beş sınıf için 150 adet nokta ölçümü yapılmıştır. Ölçümler GNSS ölçme yöntemi kullanılarak yapılmış olup, yoğun ağaçlık bölgelerde yeteri kadar uydunun görülmemesinden dolayı DGNS yöntemini ile 1-2 m hassasiyetinde ölçümlerin yapılması doğruluk ölçütü olarak dezavantaj olmuştur. Topoğrafya düşünüldüğünde en hassas sonuçların bu doğruluk hassasiyetinde alınabileceği için ölçümlere devam edilmiştir. Ölçüm sonrası proje parametrelerinin NetCAD yazılımının kendi bünyesinde bulundurduğu dönüşüm parametreleri kullanılarak UTM6°-WGS84 olacak şekilde dönüştürülmüştür. Dönüştürme sırasında belirli bir doğruluk kaybının yaşanması da olumsuz sonuç

olmuştur. Ölçülen koordinatlar ile elle vektörleştirilen uydu görüntüsü, 1/25000 ölçekli meşcere haritası, piksel ve nesne-tabanlı sınıflandırma sonuçları ile nokta bazında değerlendirme yapılmıştır. Değerlendirme sonuçlarındaki en büyük dezavantaj uydu görüntüsü ile meşcere haritasının alım ve üretim tarihleri arasındaki zamansal fark olmuştur. Aradan geçen zaman içerisinde değişen nesnelere ve arazi yüzeyleri karşılaştırma sonucunda açık bir şekilde görülmektedir. Meşcere haritaları eski tarihli tescil edilmiş olsalar bile, kullanılan uydu görüntüsünün yakın tarihli alımının yapılması belirli bir amaca uygun yapılan çalışmalar için daha uygun sonuçlar vereceğini bu çalışma ile de desteklemiştir.



KAYNAKLAR

- 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 Ekim 2007, İstanbul, 1-11.
- Ayhan E, Karşlı F ve Tunç E** (2003) Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz. *Harita Dergisi*, Harita Genel Komutanlığı, Ankara, 130 s.
- Baatz M and Schäpe A** (2000) Multiresolution Segmentation-An Optimization Approach for High Quality Multi-scale Image Segmentation. *Angewandte Geographische Informationsverarbeitung XI. Beiträge zum AGIT-Symposium*, 1999, Salzburg, Karlsruhe. Herbert Wichmann Verlag, 12-23.
- Baatz M, Benz U, Dehghani S, Heynen M, Höltje A, Hofmann P, Lingenfelder I, Mimler M, Sohlbach M, Weber M and Willhauck G** (2004) Definiens-Imaging. *eCognition Professional: User Guide 5*, Munich, 105-148.
- 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 and Strobl J** (2001) What's Wrong with Pixels? Some Recent Development Interfacing Remote Sensing and GIS. *GeoBIT/GIS*, 14 (6): 12-17.
- Blaschke T** (2010) Object Based Image Analysis for Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65: 2-16.
- Blaschke T, Hay G J, Kelly M, Lang S, Hofmann P, Addink E, Queiroz Feitosa R, Van Der Meer F, Van Der Werff H, Van Coillie F and Tiede D** (2014) Geographic Object-Based Image Analysis: Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87 (0): 180-191.
- Bock M, Xofis P, Mitchley J, Rossner G and Wissen M** (2005) Object-oriented Methods for Habitat Mapping at Multiple Scales: Case Studies from Northern Germany and Wye Downs. *Journal for Nature Conservation*, UK, 13 (2): 75-89.
- Boyacı D** (2012) CBS-Uzaktan Algılama Entegrasyonu ve Örnek Uygulama: Uydu Görüntülerinden Detay ve Otomatik Öznitelik Tespiti. *Doktora Tezi*, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Jezodezi ve Fotogrametri Ana Bilim Dalı, Konya, 96 s.

KAYNAKLAR (devam ediyor)

- Burnett C and Blaschke T** (2003) A Multi-scale Segmentation/Object Relationship Modelling Methodology for Landscape Analysis. *Ecological Modelling*, 168 (3): 233-249.
- Büyüksalih G** (2011) Doğrusal Dizin (PUSHBROOM) Görüntüleme Sistemleri. *Pamukkale University Journal of Engineering Sciences*, 6: 2-3.
- Carleer A and Wolff E** (2006) Region-Based Classification Potential for Land-Cover Classification with Very High Spatial Resolution Satellite Data. *In Proceedings of 1st International Conference on Object-based Image Analysis (OBIA 2006)*, July 4-5 2006, Salzburg University, Austria, ISBN:1682-1777, Vol. XXXVI.
- Corbane C, Raclot D, Jacob F, Albergel J and Andrieux P** (2008) Remote Sensing of Soil Surface Characteristics from a Multiscale Classification Approach. *Catena*, 75(3): 308-318.
- Çölkesen İ** (2009) Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi. *Yüksek Lisans Tezi*, Gebze Yüksek Teknoloji Enstitüsü, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Ana Bilim Dalı, Gebze, 106 s.
- Dean A M and Smith G M** (2003) An Evaluation of Perparcel Land Cover Mapping Using Maximum Likelihood Class Probabilities. *International Journal of Remote Sensing*, 24 (14): 2905-2920.
- eCognition** (2011a) Trimble Documentation. *eCognition Developer 8.7 User Guide*, München, Germany, 258pp.
- eCognition** (2011b) Trimble Documentation. *eCognition Developer 8.7 User Guide*, München, Germany, 438pp.
- Erdas** (2008) Field Guide. *ERDAS Inc.*, Atlanta, USA, 653 pp.
- Feitosa R Q, Costa G A O P, Cazes T B and Feijo B** (2006) A Genetic Approach for the Automatic Adaptation of Segmentation Parameters. *In: 1st International Conference on Object Based Image Analysis*, 4 July 2006, Salzburg, Austria. 15-21.
- Hofmann P** (2001a) Detecting Urban Features From IKONOS Data Using an Object- Oriented Approach. *First Annual Conference of the Remote Sensing & Photogrammetry Society*, 12-14 September 2001, 28-33.
- Hofmann P** (2001b) Detecting Buildings and Roads from IKONOS Data Using Additional Elevation Information. *GIS Geo-Information-System*, 2001: 6.
- Hofmann P** (2001c) Detecting Informal Settlements from IKONOS Image Data Using Methods Of Object Oriented Image Analysis - An Example From Cape Town. *Remote Sensing of Urban Areas*, Carsten (Regensburg), 107-118.
- Holland D A, Boy D S and Marshall P** (2006) Updating Topographic Mapping in Great Britain Using Imagery from High-Resolution Satellite Sensors. *ISPRS J. Photogramm. Remote Sens.*, 60 (3): 212–223.

KAYNAKLAR (devam ediyor)

- Jensen J R** (2005) *Introductory Digital Image Processing: A Remote Sensing Perspective*, ISBN: 10-0131453610, *Third ed. Prentice-Hall*, New York, 544 pp.
- Kalkan K** (2011) Kentsel Gelişim için Potansiyel Açık Alanların Belirlenmesinde Nesne Tabanlı Sınıflandırma Yöntemi ile Transfer Edilebilir Kural Dizisi Oluşturulması. *Yüksek Lisans Tezi*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Ana Bilim Dalı, İstanbul. 81 s.
- Kavzoğlu T** (2008) Uzaktan Algılama ve Uygulamaları Ders Notları (yayınlanmamış). *Yüksek Lisans Programı*, G.Y.T.E., Gebze, 18-21.
- Kavzoğlu T ve Çölkesen İ** (2010) Karar Ağaçları ile Uydu Görüntülerinin Sınıflandırılması: Kocaeli Örneği. *Harita Teknolojileri Elektronik Dergisi*, 2 (1): 36-45.
- Koç A** (1995b) Konusal Orman Haritalarının Üretilmesi ve Güncelleştirilmesinde Orman Bilgi Sisteminin Sunduğu Olanaklar. *Türkiye İkinci ARC/INFO ve ERDAS Kullanıcıları Grubu Toplantısı*, 19-20 Haziran 1995, Ankara, 28-39.
- Lillesand T M and Kiefer R W** (2000) *Remote Sensing and Image Interpretation. Fourth Edition*, John Wiley and Sons, ISBN: 0-471-15227-7, Inc. Printed in the United States of America, 753 pp.
- Lillesand T M, Kiefer R W and Chipman J W** (2007) *Remote Sensing and Image Interpretation. 6th Edition*, John Wiley & Sons, ISBN: 978-1-118-34328-9, New York, 736 pp.
- 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*, 2860-2880.
- Marangoz A M, Oruç M ve Büyüksalih G** (2004) Object-oriented Image Analysis and Semantic Network for Extracting The Roads and Buildings from IKONOS Pan-sharpened Images. *ISRPS 2004 Annual Conference*, 19 - 23 July 2004, İstanbul, Turkey, Volume XXXV, Part B3, p. 4.
- Marangoz A M** (2009) Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve CBS Ortamında Bütünleştirilmesi. *Doktora Tezi*, Yıldız Teknik Üniversitesi, YTÜ Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Ana Bilim Dalı, İstanbul, 119 s.
- Maktav D ve Sunar F** (1991) *Uzaktan Algılama: Kantitatif yaklaşım*, Hürriyet Ofset A.Ş., İstanbul, 392 s.
- Oruç M, Marangoz A M ve Karakış S** (2005) Pan-Sharp Landsat 7 Etm+ Görüntüsü Kullanılarak Piksel-Tabanlı Ve Nesne-Tabanlı Sınıflandırma Yaklaşımlarının Karşılaştırılması. *TMMOB Harita ve Kadastro Mühendisleri Odası 11. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 2-6 Nisan 2007, Ankara, 34-40.
- Pizzolato A N and Haertel V** (2003) On The Application of Gabor Filtering in Supervised Image Classification. *International Journal of Remote Sensing*, 24: 2167-3189.

KAYNAKLAR (devam ediyor)

- Pohl C and Van Genderen J L** (1998) Remote Sensing Multisensor Image Fusion in Remote Sensing: Concepts, Methods and Applications. *Int. J.*, 19(5): 823-854.
- Sandmann H and Lertzman K P** (2003) Combining High-Resolution Aerial Photography with Gradient-directed Transects to Guide Field Sampling and Forest Mapping in Mountainous Terrain. *Forest Science*, 49 (3): 429-443.
- Sesören A** (1999) *Uzaktan Algılamada Temel Kavramlar*, Mart Matbaacılık Sanatları Ltd. Şti., İstanbul, 126 s.
- 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): 2354-2364.
- Sunar F** (2011) *Uzaktan Algılama*, Anadolu Üniversitesi Yayınları, ISBN: 978- 975-06-0995-4, İstanbul, 205 s.
- Toutin T** (2003) Error Tacking in Ikonos Geometric Processing Using a 3D Parametric Model. *Photogrammetric Engineering&Remote Sensing*, Vol. 69, 43-51.
- Topan H** (2004) Yörünge Düzeltmeli IRS-1C/1D Pankromatik Mono Görüntüsünün Geometrik Doğruluk ve Bilgi İçeriği Açısından İncelenmesi. *Yüksek Lisans Tezi*, Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Jeodezi ve Fotogrametri Mühendisliği Ana Bilim Dalı, Zonguldak, 77 s.
- Trimble** (2012) *eCognition Developer User Guide*, Trimble Germany GmbH, München, 261 pp.
- Yan G** (2003) Pixel Based and Object Oriented Image Analysis for Coal Fire Research. *Ms Thesis*, The Netherlands, 80 pp.
- Yan G, Mas J F, Maathuis B H P, Zhang X and Van Dijk P M** (2006) Comparison of Pixel-Based and Object-oriented Image Classification Approaches: a Case Study in a Coal Fire Area. *International Journal of Remote Sensing*, Inner Mongolia, China, 27 (18): 4039-4055.
- Yurtseven H** (2014) Yüksek Çözünürlüklü Uydu Verileri İle Obje Tabanlı Görüntü Analizleri. *Doktora Tezi*, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Orman Mühendisliği Ana Bilim Dalı, İstanbul, 135 s.
- Zhou Q and Robson M** (2001) Automated Rangeland Vegetation Cover and Density Estimation Using Ground Digital Images and a Spectral-Contextual Classifier. *International Journal of Remote Sensing*, 22 (17): 3457-3470.
- Zhiyuan Z** (2004) Computer Classification and Geoscience Applied Research of Satellite Remote Sensing Image. *Publishing House of Science*, Beijing, 157-158.
- URL-1** <<http://www.yildiz.edu.tr/~bayram/sgi/saygi.htm>> , Ziyaret tarihi: 10.05.2016.
- URL-2** <http://www.nik.com.tr/content_sistem_uydu.asp?id=12> , Ziyaret tarihi: 21.05.2016.

ÖZGEÇMİŞ

Duygu Bıyıklı, 26.07.1988 tarihi Ankara doğumludur. İlköğretimini Ankara Aydınlikeler İlköğretim Okulu, ortaöğretimini Kastamonu AliFuat Darendede İlköğretim Okulu ve lise eğitimini Kastamonu Abdurrahman Paşa Lisesinde tamamlamıştır. 2006 yılında Ondokuz Mayıs Üniversitesi Harita Mühendisliği bölümüne başlamış olup 2010 yılında lisans eğitimini tamamlamıştır. 2013 yılında Kastamonu Üniversitesi, İhsangazi Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Harita ve Kadastro Programı, Öğretim Görevlisi olarak göreve başlamış olup, halen devam etmektedir. 2014 yılında Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Geomatik Mühendisliği Anabilim Dalında yüksek lisans eğitimini almaya başlamıştır.

ADRES BİLGİLERİ:

Adres: Kastamonu Üniversitesi, İhsangazi Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Harita ve Kadastro Programı.

Tel: (+90) 366 392 23 13/(115)

E-posta: dbiyikli@kastamonu.edu.tr