

**İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER YARDIMIYLA YOL
TESPİTİ**

YÜKSEK LİSANS TEZİ

Abdurahman Yasin YİĞİT

Danışman

Doç. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2020

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER
YARDIMIYLA YOL TESPİTİ

Abdurahman Yasin Yiğit

Danışman
Doç. Dr. Murat UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2020

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18/06/2020


Abdurrahman Yasin YİĞİT

ÖZET

Yüksek Lisans Tezi

İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER YARDIMIYLA YOL TESPİTİ

Abdurahman Yasin YİĞİT

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Murat UYSAL

Teknolojinin gelişmesi ile veri toplama yöntemleri, dünya yüzeyi hakkında daha fazla bilgi edinme fırsatı sunmaktadır. Elde edilen verilerdeki yoğunluk, bu verilerdeki anlamlı olanların çıkarımını zorunlu kılmıştır. Önceleri, istenen detayların çıkarılması operatörler tarafından manuel olarak yapılmaktaydı. Bu durum zaman ve maliyet yönünden olumsuz karşılanmaktadır. Gelişen detay çıkarma yöntemleri sayesinde, ihtiyaç duyulan nesnelerin otomatik tespiti daha hızlı ve kolay hale gelmiştir. İnsansız Hava Aracı (İHA) ile elde edilen yüksek çözünürlüklü görüntülerden bilgi almak için bir nesnenin ve çevresinin mekânsal ve spektral bilgilerini kullanmamız gerekir. Bu tür uzaktan algılanan verilerden bilgi elde etmek için piksel tabanlı yaklaşımlar uygulanırsa yalnızca spektral bilgi kullanılır. Bu nedenle, piksel tabanlı yaklaşımlar yüksek çözünürlüklü görüntü sınıflandırmasını karşılayamaz ve bilgi çıkarma yalnızca gri düzey eşikleme yöntemlerine dayandırır ve bu da kullanıcının büyük verilerle uğraşmasını gerektirir. Bu durum zengin bilgi içeriğine sahip yüksek çözünürlüklü görüntülerde uygulanan piksel tabanlı sınıflandırma yönteminde bina, yol, park vb. kesin sınırlar içeren kentsel alanlardan hassas veri çıkarımı oldukça güçleştirir. Bu eksiklik mevcut bilgi işlem teknolojilerine bağlı olarak gelişmiş görüntü analiz ve sınıflandırma yaklaşımlarını da beraberinde getirmiştir. Dolayısıyla günümüz görüntü işleme ve uzaktan algılama teknolojilerinde, nesne tabanlı sınıflandırma yaklaşımları yoğunlukla kullanılmaya başlanmıştır. Bu çalışmada benzer konumsal çözünürlüğe sahip ortofoto görüntüleri kullanılarak nesne

tabanlı sınıflandırma yöntemi ile yolların ve benzeri hatların belirlenen kural ve işlemler ile otomatik tespiti amaçlanmıştır.

Bu tez çalışmasında, İHA ile toplanan veriler fotogrametrik tekniklerle değerlendirilmiş ve Definiens eCognition yazılımında nesne tabanlı sınıflandırma yöntemi kullanılarak yol tespiti yapılmıştır. Nesne tabanlı sınıflandırma yöntemiyle; algılanan verilerin mekansal, spektral ve bağlamsal bilgi gibi farklı nesne özelliklerine göre uzaktan sınıflandırılmasının mümkün olduğu gösterilmiştir. Daha sonra, jeodezik yöntemle çizilen vektör veriler ile tespit edilen yolların karşılaştırılması yapılmıştır. Tez kapsamında görünür ve kızılötesi bölgede elde edilen görüntüler kullanılarak beş farklı çalışma yapılmıştır. İHA ile elde edilen ham veriler değerlendirilip nesne tabanlı sınıflandırma yaklaşımı ile sayısal ortamda otomatik yol tespiti ve sınıflandırılması yapılmıştır. Çalışma sonucunda ortofoto görüntüsünden nesne tabanlı yaklaşım ile tespit edilen yollar ile hâlihazır harita ve elle sayısallaştırma sonucu elde edilen yollar kullanılarak istatistiksel analiz yapılmıştır. Yapılan beş farklı çalışmada kullanıcı doğrulukları %85 ile %91 arasında değişmektedir. Genel doğruluklar ise en düşük 0.7520 en yüksek 0.8768 hesaplanmıştır. Karşılaştırılması sonucunda, elde edilen sonuçların güven aralığı içerisinde olduğu tespit edilmiştir. Bu durum, nesne tabanlı sınıflandırma yönteminin; mekânsal çözünürlüğün resimlerdeki spektral yansıma değeri ile artması durumunda, yol detaylarının otomatik olarak belirlenmesine olumlu katkıda bulunabileceğini göstermektedir.

2020, xiii + 110 sayfa

Anahtar Kelimeler: Nesne tabanlı, Detay tespiti, Otomatik yol tespiti, Sınıflandırma, İHA, Yol, Farklı sensörler

ABSTRACT

M.Sc. Thesis

Automatic Road Detection from Data Taken by Unmanned Aerial Vehicles

Abdurahman Yasin YİĞİT

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Surveying Engineering

Supervisor: Assoc. Prof. Murat UYSAL

With the development of technology, data collection methods offer the opportunity to learn more about the world's topography. The density in the data obtained made it necessary to infer the meaningful ones in these data. Previously, the extraction of the requested details was done manually by the operators. This situation is considered an adverse reaction in terms of time and cost. Thanks to the developing detail extraction methods, automatic detection of the needed objects have become faster and easier. We need to use the spatial and spectral information of an object and its surroundings to obtain information from high-resolution images obtained by the Unmanned Aerial Vehicle (UAV). If pixel-based approaches are applied to obtain information from such remotely sensed data, only spectral information is used. Therefore, pixel-based approaches cannot meet high-resolution image classification, and information extraction is based only on gray-level thresholding methods, which requires the user to deal with big data. This situation makes it very difficult to extract sensitive data from urban areas containing precise boundaries in buildings, roads, parks, etc. in the pixel-based classification method applied in high-resolution images with rich information content. This shortcoming has brought along advanced image analysis and classification approaches depending on current computing technologies. Therefore, object-based classification approaches are being used extensively in today's image processing and remote sensing technologies.

In this study, automatic detection of roads and similar lines with determined rules and processes are aimed by using an object-based classification method using orthophoto images with similar spatial resolution. In this thesis study, the data collected with UAV

was evaluated by photogrammetric techniques and road determination was made by using an object-based classification method in Definiens eCognition software. With the object-based classification method; It has been shown that it is possible to remotely classify the perceived data according to different object characteristics such as spatial, spectral, and contextual information. Then, vector data drawn by the geodetic method were compared with the detected roads. Within the scope of the thesis, five different studies have been done using the images obtained in the visible and infrared region. The raw data obtained by UAV were evaluated and automatic path detection and classification were made in a digital environment with an object-based classification approach. As a result of the study, statistical analysis was done by using the paths determined by the object-oriented approach from the orthophoto image and the paths obtained by the current map and manual digitization. User accuracy ranges from 85% to 91% in five different studies. General accuracies were calculated as the lowest 0.7520 and the highest 0.8768. As a result of the comparison, it has been determined that the results obtained are within the confidence interval. This situation shows that the object-based classification method can contribute positively to the automatic determination of the road details when the spatial resolution increases with the spectral reflection value in the pictures.

2020, xiii + 110 pages

Keywords: Object-based, Detail extraction, Automatic road detection, Classification, UAV, Road, Different sensors

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Doç. Dr. Murat UYSAL' a araştırma ve yazım süresince yardımlarını esirgemeyen Sayın Prof. Dr. Murat YAKAR, Prof. Dr. İbrahim YILMAZ, Dr. Ali ULVİ, Dr. Osman ORHAN' a, Dr. Lütfiye KUŞAK, Dr. Fatma Bünyan ÜNEL ve Dr. Muzaffer Can İBAN'a, manevi desteklerinden dolayı Adem KABADAYI, Muharrem Cihan CEYLAN' ve Araştırma Görevlisi Yunus KAYA' ya, her konuda öneri ve eleştirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teşekkür ederim.

Bu araştırma boyunca maddi ve manevi desteklerinden dolayı tüm aileme en içten teşekkürlerimi sunarım.

Abdurahman Yasin YİĞİT
AFYONKARAHİSAR, 2020

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	x
ÇİZELGELER DİZİNİ	xiii
1. GİRİŞ	1
1.1 Tezin Amacı	2
1.2 Hipotez	3
2. LİTERATÜR BİLGİLERİ	4
2.1 Literatür Taraması	4
2.1.1 İHA ile İlgili Yapılan Çalışmaların Literatür Özeti.....	4
2.1.2 Detay/Nesne Çıkarımı ve Sınıflandırma ile İlgili Literatür Özeti	6
3. GÖRÜNTÜ SINIFLANDIRMA ve DETAY ÇIKARMA YÖNTEMLERİ	15
3.1 Piksel Tabanlı Sınıflandırma Yöntemi.....	16
3.1.1 Kontrolsüz Sınıflandırma Yöntemi	17
3.1.2 Kontrollü Sınıflandırma Yöntemi.....	17
3.1.2.1 Minimum uzaklık (Minimum Distance).....	17
3.1.2.2 Paralelkenar/Paralelyüz Yöntemi (Parellelepiped)	18
3.1.2.3 Maksimum benzerlik (Maksimum likelihood)	19
3.1.2.4 Melez (Hibrit) Sınıflandırma Yöntemi.....	19
3.1.2.5 Spektral Karışım Analizi Sınıflandırma Yöntemi.....	20
3.1.2.6 Fuzzy (Bulanık) Sınıflandırma Yöntemi	21
3.2 Nesne Tabanlı Sınıflandırma Yöntemi	21
3.2.1 Görüntü Yorumlamada Temel Bileşenler	25
3.2.1.1 Görüntü İşlemede Yaklaşık Ölçek	25
3.2.1.2 Görüntü Semantikleri – Görüntü Nesneleri Arasındaki Karşılıklı İlişkiler.....	26
3.2.1.3 Segmentasyon İşlemi.....	28
4. MATERYAL ve METOT	32
4.1 Kullanılan Donanım, Veri ve Yazılımlar	32

4.1.1 Kullanılan Donanım.....	32
4.1.2 İHA Görüntü Verisi	35
4.1.3 Kullanılan Yazılımlar	35
4.2 Yöntem.....	35
4.3 Doğruluk Analizi/Karşılaştırma Verisi – Vektör Harita.....	41
5. UYGULAMA.....	47
5.1 Çalışma 1 (Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer kampüsü-RGB Görüntüler)	47
5.1.1 Veri Temini	48
5.1.2 Fotogrametrik Süreç	48
5.1.3 Nesne Tabanlı Sınıflandırma.....	49
5.2 Çalışma 2 (Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer kampüsü-RG- NIR Görüntüler).....	67
5.2.1 Veri Temini	67
5.2.2 Fotogrametrik Süreç	67
5.2.3 Nesne Tabanlı Sınıflandırma.....	71
5.3 Çalışma 3: İzmir-Foça / Ilıpınar (RG-NIR-Re (Rededge)).....	75
5.3.1 Veri Temini	76
5.3.2 Fotogrametrik Süreç	76
5.3.3 Nesne Tabanlı Sınıflandırma.....	79
5.4 Çalışma 4: Yozgat / Sorgun (RGB)	82
5.4.1 Veri Temini	83
5.4.2 Fotogrametrik Süreç	83
5.4.3 Nesne Tabanlı Sınıflandırma.....	83
5.5 Çalışma 5: Bioley-Orjulaz / İsviçre (Test alanı) (RGB-NIR-Re).....	87
5.5.1 Veri Temini	87
5.5.2 Fotogrametrik Süreç	87
5.5.3 Nesne Tabanlı Sınıflandırma.....	90
6. BULGULAR	94
7. TARTIŞMA ve SONUÇ	96
8. KAYNAKLAR.....	98
ÖZGEÇMİŞ	108

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

PAN	Normal sınıflandırma için üretici doğruluğu (Producer accuracy for normal class)
σ_c	c banttaki standart sapma
l	nesnenin çevre uzunluğu
b	nesne hattını çevreleyen uzunluk
f	Heterojenlik farkı
k	kappa katsayısı
r	Hata matrisindeki satırların sayısı
X_{ii}	Satır i ve sütun i'deki gözlemlerin sayısı
X_{ti}	Satır i'deki toplam gözlem
X_{it}	Sütun i'deki toplam gözlem
N	Matriste içerilen toplam gözlem sayısı / ana kütle
n	sayısı
p	Örnekleme alınacak birey sayısı
q	İncelenen olayın görülüş sıklığı
t	İncelenen olayın görülmeyiş sıklığı
d	t tablosuna göre bulunan teorik değer
w_c	örnekleme hatası
n_{merge}	c bandındaki ağırlık
UAN	birleştirilmiş nesne içindeki toplam piksel sayısı Normal sınıflandırma için kullanıcı doğruluğu (users accuracy for normal class)
ψ	ölçek parametresi

Kısaltmalar

3B	3 boyutlu
CAD	Computer aided design
DSM	Digital surface model - Sayısal yüzey modeli
DTM	Digital terrain model - Sayısal arazi model
GPS	Global position system
İHA	İnsansız hava aracı
KIA	Kappa index of agreement
MRF	Markov random field
MS	Multispectral
nDSM	Normalized Digital Surface Model - Normalize Edilmiş Sayısal Yüzey Modeli
NDVI	Normalized difference vegetation index
NIR	Near Infrared
NN	Neast neighbors
PAN	Pankromatik
PPK	Post Processing kinematic
RF	Random Forest
RGB	Red-Green-Blue

Kısaltmalar (Devam)

RG-NIR	Red-Green-Near Infrared
RG-NIR-Re	Red-Green-Near Infrared-Red Edge
RTK	Real time kinematic
SVM	Support vector machine
UA	Uzaktan algılama
YKN	Yer kontrol noktası



ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1	Piksel tabanlı sınıflandırma yöntemleri.....	17
Şekil 3.2	Minimum uzaklık yöntemi	18
Şekil 3.3	Paralelkenar yöntemi.....	18
Şekil 3.4	Maksimum benzerlik yöntemi	19
Şekil 4.1	İHA sınıflandırması.....	32
Şekil 4.2	Phantom 3 Professional İHA	32
Şekil 4.3	Sensefly Ebee Plus İHA	33
Şekil 4.4	Sensefly Ebee X İHA ve MicaSense RedEdge-M kamera.....	33
Şekil 4.5	Parrot Bluegrass İHA ve Parrot Sequoia+ Kamera.....	34
Şekil 4.6	Mapir Survey 3 Kamera	34
Şekil 4.7	Fotogrametrik süreç.	36
Şekil 4.8	Fotogrametrinin sınıflandırılması.	37
Şekil 4.9	Pix4d programında süreç takibi.	39
Şekil 5.1	İş akış şeması.	47
Şekil 5.2	Afyon ilinin konumu ve coğrafi koordinatları.....	47
Şekil 5.3	Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsü.	48
Şekil 5.4	Satranç tahtası segmentasyonu (Object Size: 50).	49
Şekil 5.5	Dörtlü ağaç segmentasyonu (Scale parameter: 50).....	50
Şekil 5.6	Kontrast bölme segmentasyonu (Chessboard Tile Size: 100).	50
Şekil 5.7	Üç ayrı katmanda oluşturulan görüntü segmentasyonu sonrasındaki görüntü nesnelerinin hiyerarşik ağ yapısı (Karakış vd. 2005).	51
Şekil 5.8	Çoklu çözünürlüklü segmentasyon için ölçek parametresinin diyagramı.....	53
Şekil 5.9	Farklı ölçekteki çoklu çözünürlüklü segmentasyon.....	53
Şekil 5.10	Ortofoto görüntüsü için ölçek parametresi araştırması.	55
Şekil 5.11	Ortofoto görüntüsü için şekil ve bütünlük parametresi araştırması.	56
Şekil 5.12	Sınıfların birbiri ile karışması	57
Şekil 5.13	eCognition yazılımında elle müdahale.	58
Şekil 5.14	eCognition yazılımında segmentlerin elle düzeltilmesi.	58
Şekil 5.15	Çalışma temel aşamaları.....	59
Şekil 5.16	Sınıflandırma aşaması.	60

Şekil 5.17 “Class Hierarchy” ve “Feature View” pencereleri ve sınıf ekleme.	60
Şekil 5.18 Sınıflandırmada kullanılan kural setleri ve değerleri.	61
Şekil 5.19 Sınır ve şekil düzeltme.	62
Şekil 5.20 Tespit edilen yollar (Sol üst: ortofoto – Sağ üst: sınıflara atılmış birleştirilmiş segmentler – Sol alt: Ortofoto ve tespit edilen yollar – Sağ alt: Tespit edilen yollar.	62
Şekil 5.21 Genelleştirme sonrası ortofoto üzerinde tespit edilen yollar.	63
Şekil 5.22 Örnek seçilen bazı segmentler ve sınıflar.	64
Şekil 5.23 Referans kabul edilen vektöre harita ve sınıflar (1:yol – 0: yol olmayan).	65
Şekil 5.24 Referans kabul edilen vektöre harita ve random point (2988 tane).	66
Şekil 5.25 RG-NIR dalga boyları.	67
Şekil 5.26 Mapir Survey 3 kamera ile çekilmiş örnek resim.	68
Şekil 5.27 Mapir Survey 3 kamera ile çekilmiş örnek kalibrasyon levhası.	69
Şekil 5.28 Örnek kalibrasyon levhası fotoğraf çekimi.	69
Şekil 5.29 Fotoğrafların kalibre edilmesi.	70
Şekil 5.30 Fotoğrafların Pix4D yazılımına aktarılması (RG-NIR).	70
Şekil 5.31 Pix4D yazılımında üretilen ürünler.	71
Şekil 5.32 2.Çalışma için (RG-NIR) segmentasyon.	72
Şekil 5.33 2.Çalışma için (RG-NIR) sınıflandırma aşamaları.	74
Şekil 5.34 2.Çalışma için (RG-NIR) sınıflandırma sonuçları.	74
Şekil 5.35 İzmir ilinin konumu ve coğrafi koordinatları.	75
Şekil 5.36 Ilıpınar Köyü sınırları içerisindeki çalışma alanı ve coğrafi koordinatları. ..	76
Şekil 4.37 Parrot Sequoia+ kamera ile çekilmiş örnek kalibrasyon levhası.	77
Şekil 5.38 3.Çalışma için (RG-NIR-Re) fotoğrafların yazılıma eklenmesi.	77
Şekil 5.39 Parrot Sequoia+ kamera yansıma değerlerinin tanıtılması ($g=0.18$).	78
Şekil 5.40 3.Çalışmaya ait her bant için ortofoto (sol) ve DSM (sağ).	78
Şekil 5.41 3.Çalışma için (RG-NIR-Re) segmentasyon.	79
Şekil 5.42 3.Çalışma için (RG-NIR) sınıflandırma kural setleri.	80
Şekil 5.43 3. Çalışma için (RG-NIR-Re) sınıflandırılmış görüntü.	80
Şekil 5.44 Yozgat ilinin konumu ve coğrafi koordinatları.	82
Şekil 5.45 Yozgat – Sorgun karayolu.	82
Şekil 5.46 4.Çalışma için (RGB) ortofoto.	83

Şekil 5.47 4. Çalışma için (RGB) segmentasyon.	84
Şekil 5.48 4. Çalışma için (RGB) sınıflandırma aşamaları.	85
Şekil 5.49 4. Çalışma için (RGB) sınıflandırılmış görüntü.	85
Şekil 5.50 Bioley-Orjulaz / İsviçre ve coğrafi koordinatları.	87
Şekil 5.51 5. Çalışma için (RGB-NIR-Re) kalibrasyon levhaların fotoğrafları.	88
Şekil 5.52 5. Çalışma için (RGB-NIR-Re) fotoğrafların yazılıma eklenmesi.	89
Şekil 5.53 MicaSense RedEdge-M kamera yansıma değerlerinin tanıtılması.	89
Şekil 5.54 5. Çalışma alanına ait her bant için ortofoto (sol) ve DSM (sağ).	90
Şekil 5.55 5. Çalışma alanı için (RGB-NIR-Re) segmentasyon.	90
Şekil 5.56 5. Çalışma için (RGB-NIR) sınıflandırma aşamaları.	91
Şekil 5.57 5. Çalışma için (RGB-NIR) sınıflandırma aşamaları.	92

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 4.1 Phantom 3 Professional İHA ve kamera Teknik Özellikler	32
Çizelge 4.2 Sensefly Ebee Plus İHA ve S.O.D.A kamera teknik özellikleri	33
Çizelge 4.3 Sensefly Ebee X ve MicaSense RedEdge-M kamera teknik özellikleri	33
Çizelge 4.4 Parrot Bluegrass İHA ve Parrot Sequoia+ Kamera teknik özellikleri.....	34
Çizelge 4.5 Mapir survey 3 kamera teknik özellikleri.....	34
Çizelge 5.1 Literatürdeki temel RGB bant indeksleri	59
Çizelge 5.2 1.Çalışma için doğruluk değerlendirmesi.....	64
Çizelge 5.3 1.Çalışma için Kappa İstatistik tablosu	64
Çizelge 5.4 1.Çalışma için doğruluk analizi	66
Çizelge 5.5 2.Çalışma için seçilen segmentasyon değerleri	72
Çizelge 5.6 Literatürdeki bazı RG-NIR bant indeksleri	73
Çizelge 5.7 2.Çalışma için nesne tabanlı sınıflandırma doğruluk analizi.....	74
Çizelge 5.8 2.Çalışma için nesne tabanlı sınıflandırma için kapa istatistiği.....	74
Çizelge 5.9 2.Çalışma için nesne tabanlı sınıflandırma doğruluk sonuçları.....	75
Çizelge 5.10 Parrot Sequoia+ kamera yansıma değerleri	78
Çizelge 5.11 2. Çalışma alanı için seçilen segmentasyon değerleri	79
Çizelge 5.12 3.Çalışma için nesne tabanlı sınıflandırma doğruluk analizi.....	81
Çizelge 5.13 3.Çalışma için nesne tabanlı sınıflandırma için kapa istatistiği.....	81
Çizelge 5.14 3.Çalışma için nesne tabanlı sınıflandırma doğruluk sonuçları.....	82
Çizelge 5.15 4. Çalışma için seçilen segmentasyon değerleri.....	84
Çizelge 5.16 4. Çalışma için nesne tabanlı sınıflandırma doğruluk analizi.....	86
Çizelge 5.17 4. Çalışma için nesne tabanlı sınıflandırma için kapa istatistiği.....	86
Çizelge 5.18 4. Çalışma için nesne tabanlı sınıflandırma doğruluk sonuçları.....	86
Çizelge 5.19 5. Çalışmada kullanılan MicaSense kamera yansıma değerleri.....	89
Çizelge 5.20 5. Çalışma için seçilen segmentasyon değerleri.....	90
Çizelge 5.21 5. Çalışma için doğruluk değerlendirmesi	92
Çizelge 5.22 5. Çalışma için Kappa İstatistik tablosu	93
Çizelge 5.23 5.Çalışma için doğruluk sonuçları.....	93
Çizelge 6.1 Genel doğruluk tablosu.....	95

1. GİRİŞ

Hava fotoğrafları, İHA verileri, lazer tarayıcı verileri ve uydu görüntüleri gibi uzaktan algılama yöntemleri kullanıcılara; yol, köprü, bina gibi insan yapımı nesnelerin yanı sıra bitki örtüsünün karakteristiği ve özellikleri gibi dünyanın topografyası hakkında birçok bilgi sağlamaktadır. Hava fotoğrafları ve uydu görüntüleri olmadan istenen bilgi ve özellikleri toplamak ve güncellemek maliyet açısından olumsuz olmasının yanında zaman yönünden uzun süreler almaktadır. Hava fotoğrafları ve uydu görüntüleri hakkındaki veriler klasik operatörler tarafından uzun zamandır manuel olarak tespit edilmiştir. Otomasyonun amacı hızı artırmak ve değerlendirme maliyetlerini azaltmaktır. Otomatik detaylandırma kapsamında yürütülen araştırma çalışmaları, öncelikle binaların ve yolların sayısal görüntülerden otomatik olarak çıkarılmasına odaklanmıştır. Yollar ve binalar; yüzey kaplaması, geometrik şekil gibi karakteristik özelliklere sahip olan genişlik, diğer detaylara kıyasla bu detayların tanımlanmasını ve belirlenmesini kolaylaştırır. Görüntü işleme tekniklerine dayalı yarı ve tam otomatik yaklaşımlarla görüntü analizi için çeşitli sınıflandırma teknikleri kullanılmaktadır.

Bugüne kadar kullanılan yaklaşım, işleme birimi piksel olan piksel tabanlı sınıflandırma yöntemidir. Bu yaklaşımlarda, pikselin renk değerleri ve piksellerin komşuluk ilişkileri irdelenmektedir. Bu yaklaşımların amacı, arazi örtüsü sınıflarına ve özelliklerine göre bir görüntüdeki tüm pikselleri otomatik olarak birleştirmektir. Günümüzün görüntü işleme teknolojilerinde, klasik sınıflandırma yaklaşımları olan piksel tabanlı yöntemlere ek olarak nesne tabanlı yöntemler kullanılmaktadır. Piksel tabanlı klasik yöntemlerin yapısı nedeniyle yeni bir yaklaşımın yani nesne tabanlı sınıflandırma yöntemlerinin kullanılmasını gerektirmiştir. Yüksek çözünürlüklü görüntülerden elde edilen zengin bilgi içeriği, piksel tabanlı sınıflandırma yaklaşımlarına tam olarak yansıtılamaz. Bunun nedeni, bu sınıflandırma yaklaşımlarının temelini, ayrı ayrı piksellerin gri değerlerine dayandırılmasıdır. Böylece sınıflandırma için sadece spektral bilgi kullanılmış olunur. Bu tür yaklaşımda kullanılan algoritmaların daha iyi sonuç vermesi için, yapısal veya dokusal ek bilgiler ve spektral bilgilerin kullanılması gerekmektedir.

Otomatik yol çıkarımı ile ilgili literatürde farklı yaklaşımlar denenmiştir. Bunlar; amaçları, mevcut bilgileri ve yollar hakkında kabulleri bakımından farklılık gösterirler. Bu yaklaşımları sınıflandırmak ve analiz etmek için çeşitli kriterler öngörülebilir, ancak

başlangıç sürecindeki en etkili faktör görüntülerin çözümlenmesi ve bir operatörün ekstraksiyon sürecini başlatma ve takip etme gereksinimidir. Çözünürlük, bir görüntüdeki yatay piksel sayısının ve dikey piksel sayısının çarpımı olarak ifade edilir (Gonzalez, 2002). Görüntü çözünürlüğü, yolların ve diğer nesnelerin tanımlanması üzerinde güçlü bir etkiye sahiptir.

Tez çalışmamızda ise İHA platformu ile elde edilen farklı sensörlere sahip kameralar ile çekilmiş ham verileri değerlendirip nesne tabanlı sınıflandırma yaklaşımı ile yolların ve diğer nesnelerin otomatik olarak çıkarımı ve sınıflandırılması amaçlanmaktadır.

1.1 Tezin Amacı

İnsan popülasyonunun giderek artması ve buna paralel olarak duyulan ulaşım ihtiyaçlarının karşılanması ve düzenli bir kent yapısının oluşturulması için birincil faktör her ihtiyacı optimum seviyede karşılayabilecek bir ulaşım ağı oluşturmaktır. Ulaşım ağı sayesinde düzenli bir kent yapısına, zaman tasarrufuna, hızlı altyapı hizmetlerine sahip olunur. Mühendislik projelerinin yapılacağı alanlar için genel anlamda ulaşım ağının uygun olduğu bölgeler tercih edilmektedir. Projelere altlık olması amacıyla yolların tespiti önemli bir adım olarak karşımıza çıkmaktadır. Bu anlamda yoğun veri kümeleri içinden yolların çıkarımı ve sınıflandırılması önem arz etmektedir. Uzun yıllardır manuel olarak yapılan bu çıkarım ve sınıflandırma işlemi, teknolojinin gelişimi ve yüksek donanımlı bilgisayarların üretilmesi ile otomatik olarak yapılabilmektedir. Otomatik yol çıkarımı ile hız ve maliyet konusunda önemli tasarruflar sağlanmaktadır. Son yıllarda elde edilen yüksek çözünürlüklü görüntülerden otomatik yol çıkarımı için yeni sınıflandırma arayışlarına girilmiştir. Sınıflandırma işlemi, yeryüzündeki benzer spektral yansıtma değerine sahip nesnelerin aynı sınıf altında toplanması işlemi olarak genelleştirilebilir. Diğer bir ifadeyle, görüntüyü meydana getiren her bir pikselin bütün bantlardaki değerlerinin diğer pikseller ile karşılaştırılarak benzer piksellerin, kullanıcının belirlemiş olduğu sınıflara veya sınıf sayısına ayrılması işlemidir (Campbell 1996). Bir görüntüyü sınıflandırırken arazi türleri farklı renklerle ifade edilir. Sonuç olarak ortaya bir görüntü yerine içinde çeşitli arazi örtüsünü barındıran bir harita oluşur (Bergsjö 2014). Sınıflandırma işleminde; nesnelere ait bant, şekil, doku ve komşuluk özellikleri veya bunların kombinasyonları kullanılarak gri renk tonundaki nesneler oluşturulur. Sonrasında bu gri renk tonundaki nesnelerden çıkarılması istenilen detaylar (yol, bina,

yeşil alan, toprak vb.) için belirlenen kurallar ile nesne sınıflandırması yapılır (Pankiw 2013). Oluşturulan kombinasyon da bir nesne, sadece bir sınıfa ait olabilmektedir. Tüm sınıflar için ayrı kural tanımlaması yapılır ve sınıflandırma işlemi tamamlanır (Marangoz 2009).

Geliştirilen sınıflandırma yöntemleri kullanılarak bu görüntüler hızlı ve kolay bir şekilde istenilen detayların çıkarımına yardımcı olmaktadır. Özellikle, yüksek çözünürlüklü görüntülere yönelik yeni sınıflandırma yöntemlerinin/kurallarının geliştirilmesi ile birlikte, kentsel alanlara ait nesnelerin haritalanması (bina, yol, yeşil alan, vb.) ve bunların Coğrafi Bilgi Sistemleri/Kent Bilgi Sistemleri amaçlarına yönelik kullanılması mümkün hale gelmektedir (Maktav 2010). Genel olarak görüntü sınıflandırma işlemini piksel-tabanlı ve nesne tabanlı olmak üzere iki ana başlık altında toplanmaktadır. Klasik piksel tabanlı sınıflandırma yöntemlerinde, sadece piksellerin gri değerine dayalı detay çıkarımı esastır. Piksel tabanlı sınıflandırma yönteminin kullanıldığı zengin bilgi içeriğine sahip çok yüksek çözünürlüklü görüntülerde; bina, yol, park vb. kesin sınırlar içeren kentsel alanlardan hassas veri çıkarımı oldukça güçtür. Bu eksiklik mevcut bilgi işlem teknolojilerine bağlı olarak gelişmiş görüntü analiz ve sınıflandırma yaklaşımlarını da beraberinde getirmiştir. Dolayısıyla günümüz görüntü işleme ve uzaktan algılama teknolojilerinde, nesne-tabanlı sınıflandırma yaklaşımları yoğunlukla kullanılmaya başlanmıştır (Marangoz 2009). Bu çalışmada benzer konumsal çözünürlüğe sahip ortofoto ve çok yüksek çözünürlüklü sayısal görüntüler kullanılarak nesne tabanlı sınıflandırma yöntemi ile kentsel alanlardaki yolların ve benzeri hatların belirlenen kural ve işlemler ile otomatik çıkarımı amaçlanmıştır.

1.2 Hipotez

İHA ile elde edilen görüntüler kullanılarak yüksek kalitede yoğun veri içeren sayısal haritalar üretilebilir. Bu üretilen haritalar çeşitli projelerde altlık olarak kullanılabilir. Elde edilen haritalardan ihtiyaç duyulan detaylar manuel veya otomatik bir şekilde vektör hale getirilebilir. Otomatik olarak vektör harita üretmek için öncelikli olarak yol gibi çıkarılması istenilen detayların tespiti ve sınıflandırılması yapılır. Sınıflandırılması yapılan detaylar otomatik bir şekilde vektör hale getirilir.

2. LİTERATÜR BİLGİLERİ

2.1 Literatür Taraması

İnsansız hava araçları (İHA) günümüze kadar birçok farklı alanda kullanılmıştır. Bu araçlar genellikle yurtdışında kendisine farklı uygulama alanı bulmuştur. Ülkemizde ise teknolojinin gelişimi ile beraber farklı alanlarda da kullanılmaya başlanmıştır.

Bu literatür çalışmasında ilk önce insansız hava aracının kullanarak yapılan fotogrametrik çalışmalar anlatılacak, ardından farklı veri toplama metotları kullanarak (uydu görüntüleri, hava fotoğrafları, lazer verileri vb.) detay belirleme/çıkartımı ve nesne sınıflandırma ile ilgili yapılan çalışmalara değinilecektir.

2.1.1 İHA ile İlgili Yapılan Çalışmaların Literatür Özeti

Bigras (1997) çalışmasında arkeolojik araştırmalarda hava fotoğrafçılığında kullanılan platformlardan bahsetmektedir. Bu platformların avantajları ve hangi alanlarda kullanıldıkları anlatılmaktadır.

Everaerts (2008) çalışmasında insansız hava araçlarının uzaktan algılama ve haritalama çalışmalarında kullanımını değerlendirdi ve yorumladı.

Peng vd. (2008) kentsel gelişmeyi ve değişiklikleri daha iyi gözlemlemek için insansız zeplin kullanılması çalışmalarını yapmıştır. Çekilen fotoğraflar sayesinde yüksek çözünürlüklü hava görüntüleri elde etmişlerdir.

Laliberte vd. (2011) çalışmasında New Mexico'nun güneyindeki mera alanlarının bitki özelliklerini belirlemek için bir İHA üzerine kurulan çok bantlı bir kamera tarafından belirlenen mera alanlarının görüntülerini elde etmişlerdir. Çalışmada elde edilen çok sayıda görüntüyü işlemek için, dosya dönüştürme, bantlama, radyometrik düzeltme ve ortektifikasyon gerçekleştiren otomatik bir grup işleme yöntemi geliştirdiler. Geliştirdikleri bu yöntem ile elde edilen görüntüler işlenerek alana ait bitki karakterlerini çıkarmışlardır. Sonuçları Worldview-2 uydusundan elde edilen görüntülerle karşılaştırdılar. Karşılaştırma sonucunda, İHA'dan elde edilen çok bantlı görüntülerin ve Worldview-2 uydusundan elde edilen görüntülerin büyük ölçüde örtüşmediği

görülmüştür. Bu çalışma sonucunda İHA'lara monte edilmiş çok bantlı kameralar ile çalışma alanına ait yüksek çözünürlüklü kalitede veri elde etmek için uygun araçlar olduğu gösterilmiştir. Ayrıca İHA'dan elde edilen görüntülerin değişim takibi için kullanılabileceği gösterilmiştir.

Çömert vd. (2012) birçok profesyonel disiplin için hızlı, hassas ve detaylı haritalar ve bu haritalardan üretilen verilere ihtiyaç duyulduğunu aktarmıştır. Bu verilere uzaktan algılama ve fotogrametrik algılayıcı sistemleri kullanılarak başarıyla ulaşılabilmekte olduğunu belirtmiştir. Gelişen teknolojiyle birlikte, yeni bir algılama platformu olan İHA'lar fotogrametri ve uzaktan algılama için birçok kullanım bulmuşlardır. Bu araçlar; arkeolojide ve kültürel mirasın belgelenmesi, büyük ölçekli haritalama, tarım uygulamaları ve afet yönetimi gibi pek çok alanda özellikle küçük alanları kapsayan çalışmalarda hızlı, hassas, uygun maliyetli ve tekrarlı ölçüm kabiliyetleri nedeniyle kullanılmıştır. Bu çalışmada, İHA'ların fotogrametri ve uzaktan algılama amacıyla kullanılması olanakları incelenmiştir. Bu bağlamda, bu tip araçların hangi alanlarda kullanıldığı, fotogrametrik veri toplama ve üretim yöntemleri açıklanmaktadır.

Tekin vd. (2014) veri toplamada uyduların ve uçakların mevcut olarak kullanıldığı bazı uydu sensörlerinin çözünürlüğünün arttırıldığı halde bulut kaplı alanların ve bitki yetiştirme sürecinde tekrarlanan ölçümlerin yapılmasında bazı önemli kaygıların devam ettiğini çalışmada gözlemlemiştir. Hava araçları ile yapılan uzaktan algılamanın, yüksek çözünürlüklü veri toplama ve herhangi bir zamanda tekrarlanan uçuşlara için izin verdiği çalışmada aktarılmıştır. Fakat aynı zamanda büyük alanlarda yapılan çalışmalarda ölçüm yapılmasının gerekliliği, yüksek maliyet ve esnek olmayan çalışma saatleri bu tarz uygulamalardaki çekinceler olarak gösterilmiştir. Son zamanlarda, önceleri ordu tarafından kullanılan insansız hava araçlarının sivil hayata girmiş olduğuna değinilmiş ve küçük insansız hava taşıtlarındaki gelişmeler ürün izleme ve yönetimi için yeni çözümler sunduğu belirtilmektedir. Bu makale, İHA teknolojisinin ve uzaktan algılamada kullanılan farklı algılayıcı tiplerinin tarım çalışmalarında kullanımındaki son gelişmeleri özetlemeyi amaçlamaktadır.

Karkınlı vd. (2015) İHA'ların düşük maliyetli olması ve bu platformlarda farklı özelliklere sahip minyatür ölçüm cihazlarının taşınması Harita Mühendisliği

uygulamalarında kullanılmasını teşvik etmiştir. GPU teknolojilerinin yaygınlaşmasıyla birlikte İHA'ların topografik haritalamada kullanımı yaygınlaşmıştır. Bu çalışmada, sivil standartları karşılayan bir İHA kullanarak 100 m'lik yükseklikten 600x800m'lik bir alana ait 720*720 piksel yüksek çözünürlüklü görüntüler elde edilmiştir. Elde edilen görüntüler, Tesla GPU destekli bir bilgisayarda yoğun eşleştirme tekniği kullanılarak işlendi ve ilgili yüzeyin konumsal çözünürlüğünün çok yüksek olduğu DTM verileri elde edildi. Yapılan kontrollerde, 6 cm konum doğruluğu ve yaklaşık 8 cm yükseklik doğruluğu gözlemlenmiştir.

Kahveci ve Can (2017) İHA için, uzaktan kumandalı ve/veya görevini otomatik olarak herhangi bir pilot ve yolcu olmadan yürüten, yalnızca uygun/gerekli olan donanımı (video kamera, fotoğraf makinesi, GNSS, lazer tarama cihazı, vb.) taşıyan bir tür uçaktır demiştir. Ayrıca çalışmasının içerisinde İHA'ların sivil ve bilimsel amaçlı mesleki kullanımlarının ülkemizde (Türkiye'de) ve tüm dünyada hızla artmakta olduğundan bahsetmiştir. Bu nedenle bu konunun gelecek yıllarda daha fazla gündem oluşturacağını düşündüğünü aktarmıştır. İHA'ların bu denli yoğun kullanılacağını düşünmesinin ana nedenleri olarak; İHA'ların özellikle sivil amaçlar için kullanılmasının çok çeşitli uygulamalara sahip olduğu ve oldukça farklı mesleki alanlarda (örneğin harita yapımı) kullanımlarda yüksek doğruluk, zaman ve maliyet tasarrufu sağlayacağı düşünülmektedir.

2.1.2 Detay/Nesne Çıkarımı ve Sınıflandırma ile İlgili Literatür Özeti

Smith (1997) akarsular ile ilgili su baskını, evre ve deşarjını tespit etmek için uzaktan algılama uygulamasını ilk gözden geçiren araştırmacılardan biridir. O zamandan beri araştırmacılar; detay tespitinde, taşkın alanlarının belirlenmesinde, taşkın risk haritalama ve hasar değerlendirmesinde uzaktan algılama platformları verilerini kullanmaktadır.

Bacher ve Mayer (2005) yüksek çözünürlüklü çok bantlı uydu görüntülerinden yolların çıkarılması için otomatik bir yaklaşım önermişlerdir. Görüntüleri ilk önce her piksel için üyelik değerlerini içeren “yol sınıfı görüntüsü” olarak sınıflandırmışlar. Sınıflandırma sonuçları ve bir dizi geometrik kısıtlama kullanılarak Steger çizgileri yol hipotezi olarak değerlendirmişlerdir. Yol hipotezlerinin doğrulanması için spektral bilgileri kullanmak; örneğin küçük alanların veya çitlerin neden olduğu yanlış pozitiflerin sayısını önemli

ölçüde azaltacağından bahsetmişlerdir. Ek olarak, yol üzerindeki ağaç gölgelerin neden olduğu kısımlar, parametreler uyarlanmadan spektral bilgiler ile otomatik çıkarılabileceğinden bahsetmişlerdir. Gelecekteki çalışmalar için, örneğin asfalt yol ile toprak yolları otomatik olarak farklı yol sınıflarına sınıflandırmak için yolların spektral özelliklerini ve yol genişliği ile birlikte kullanılması gerektiğini önermişler.

Marangoz vd. (2005) çalışmalarında, geleneksel sınıflandırma yöntemlerinden olan piksel tabanlı sınıflandırma yönteminin sadece piksellerin gri değerine dayandığı için yalnızca spektral bilgi sınıflandırma aşamasında kullanılmasından dolayı nesne tabanlı sınıflandırma yöntemini kullandıklarından bahsetmişlerdir. Kullandıkları yöntem olan nesne tabanlı sınıflandırma ile görüntüyü önce segmentlere ayırdıklarından daha sonra da spektral, uzaysal ve yapısal bilgilerden yararlanılarak sınıflandırma ve nesne çıkarımı yaptıklarından bahsetmişlerdir. Sonuç olarak nesne tabanlı sınıflandırma yöntemi ile otomatik bir şekilde detay çıkarımının başarılı olduğundan ve elde edilen verilerin coğrafi bilgi sistemlerine entegre edilebileceğine değinmişlerdir.

Wang vd. (2005) geleneksel çok bantlı (multispektral – MS) görüntülerden sınıflandırma ve yol çıkarma yöntemlerinin, yolların tek tek piksellerin spektral özelliklerine göre diğer zemin özelliklerinden ayrılmasını kapsadığından bahsetmişler. Yüksek çözünürlüklü uydu görüntülerinin çeşitli özelliklerinden yararlanmak için, çalışmalarında; MS görüntüden spektral bilgileri, pankromatik (Pan) görüntüden uzamsal bilgilerle birleştirmişler. İlk olarak, düşük çözünürlüklü MS görüntüsü ile yüksek çözünürlüklü Pan görüntüsünü birleştirmişler. Ardından, pan görüntüsü keskinleştirilmiş (pan-sharpened). Bu işlemden sonra görüntüden, yol dışı nesneleri ve yolları içerebilecek nesneler sınıflandırılmış. Sınıflandırılmış yollar daha sonra sınıflandırılmış yol görüntüsünden yönlü doku bilgisi ve Pan görüntüsünden kenar bilgisi kullanılarak bölümlere ayrılmış ve yeniden sınıflandırılmış. Doku, kenar, şekil ve boyut özelliklerini kullanarak; küçük araba yolları, ev çatıları ve otoparklar gibi yol dışı nesneler etkili bir şekilde çıkarılmış. Kentsel alanlardaki sınıflandırılan yolların kalite değerlendirmeleri, çıkarılan ana yolların uzunlukları açısından tamlığı ve doğruluğu sırasıyla %90, 97 hesaplanmıştır.

Geçen ve Sarp (2007) düşük ve yüksek çözünürlük görüntülerden yolların çıkarımını yapmışlar. Yolları otomatik ve yarı otomatik yöntemlerle belirlemişler ve çözünürlüğün

yöntemler üzerindeki etkisini incelemişler. Sonuç olarak yüksek çözünürlükte olan görüntülerdeki nesnelerin çoğunun düşük çözünürlüklü görüntülerde net olmadığı ve çözünürlüğün detay çıkarımında önemli bir etkisinin olduğu aktarılmıştır.

Karslı vd. (2009) çalışmalarında bina ve yol nesnelerini hava fotoğraflarından çıkarımını gerçekleştirmişlerdir. Karslı ve arkadaşları hava fotoğraflarını üç gruba ayırmışlardır. Bunlar infrared (kızılötesi) renkli, siyah beyaz renkli, normal renkli gruplardır. Çalışma kapsamında infrared renkli hava fotoğrafları tercih edilmiş. Bina ve yol detaylarının belirlenmesi için dört farklı metot kullanılmış. Bunlar; Canny, Sobel, Roberts, Prewitt kenar arama yöntemleridir. Çalışma kapsamında indeks değerleri birbirine yakın olan nesne kenarlarının ayırt edilmesinin oldukça zor olduğu belirtilmiş. Kullanılan dört yöntem kırsal ve kentsel alanlarda test edilmiş ve sonuçların başarılı olduğu gözlemlenmiştir. Binaların çatılarının kurşun veya beton olmasından dolayı ve aynı zamanda yollar ile beton zemininde aynı sebeplerden dolayı ayırt edilmesinin zorlaştığı tespit edilmiş. Fakat bazı iyileştirme teknikleri sayesinde bu sorun çözülmüş. Çalışma sonucunda, kızılötesi hava fotoğraflarının binalar ve yollar gibi diğer nesnelerden farklı spektral yansıma veren nesneleri otomatik olarak tespit edebildiği gösterilmiştir.

Kalkan ve Maktav (2010) çalışmalarında uydu görüntülerinde mekânsal çözünürlük artmasından dolayı piksel tabanlı yöntem ile nesne tabanlı sınıflandırma yöntemini karşılaştırmışlardır. Piksel tabanlı sınıflandırma kapsamında hem kontrollü hem de kontrolsüz sınıflandırma yöntemi kullanılmış. 8 tematik sınıf ataması yapılmış. Kontrollü sınıflandırmada seçilen örneklemelerin sınıflandırma sonucunu etkilediğinden bahsedilmiş. Nesne tabanlı sınıflandırmada en önemli aşama olan segmentasyon aşamasının önemine ve segmentasyon aşamasından önce girilen değerlere değinilmiş. Segmentasyondan önce girilen değerlerin deneme yanılma yoluyla projeye en uygun değerlerin bulunması gerektiği vurgulanmış. Nesne tabanlı sınıflandırmada da 8 adet sınıf hiyerarşisi belirlenmiş. Sınıflandırma sonucunda her iki yöntem içinde doğruluk analizi yapılmıştır. Seçilen çalışma alanın küçük olmasından dolayı her iki yöntem ile de başarılı sonuçlar alınmış fakat nesne tabanlı sınıflandırma yöntemi ile daha anlamlı sonuçlar elde edilmiştir.

Bayburt ve Maktav (2012) çalışmalarında uydu görüntülerinde mekânsal çözünürlük artmasından dolayı piksel tabanlı yöntem ile nesne tabanlı sınıflandırma yöntemini karşılaştırmışlardır. Sınıflandırma sonucunda her iki yöntem içinde doğruluk analizi aktarılmış. Seçilen çalışma alanın küçük olmasından dolayı her iki yöntem ile de başarılı sonuçlar alınmış fakat nesne tabanlı sınıflandırma yöntemi ile daha anlamlı sonuçların elde edildiğini belirtmişlerdir.

Yıldız (2012) çalışmasında, 60 cm yersel çözünürlüklü uydu görüntüsü ile 30 cm yersel çözünürlüklü hava fotoğraflarını kullanarak farklı kombinasyonlarda segmentasyon işlemleri yapmış ve en yakın komşuluk yöntemiyle sınıflandırmıştır. Yapılan sınıflandırmaların doğruluk analizlerini incelemiştir. Segmentasyonda kullanılan parametrelerin sınıflandırmanın üzerindeki etkilerinin ayrıntılı olarak analiz ederek, görüntü özellikleri ve parametre tercihi arasındaki ilişki hakkında bazı sonuçlara varmıştır. İki farklı görüntü için 20-50 aralığında ölçek parametresi ve 0.1-0.3 aralığında şekil parametresi seçilerek yüksek doğrulukta sonuçların elde edildiğini tespit etmiştir. Benzer özelliklere sahip veriler için bu parametre değerlerinin kullanılmasını önermiştir. Bununla birlikte, genel bir kural oluşturmak için farklı veri kümeleri ve sınıf tipleri için çalışmalara ihtiyaç olduğunu vurgulamıştır.

Fırat vd. (2015) çalışmalarında multispektral hava fotoğrafları ile SYM ve SAM kullanılarak nesne tabanlı sınıflandırma yönteminde yararlanarak otomatik bir şekilde detay çıkarımı çalışması yapmıştır. Çalışma kapsamında, bina başta olmak üzere bitki örtüsü ve su yüzeyi detaylarının otomatik çıkarımı incelenmiştir. Nesne çıkarımı için yükseklik modelinden ve Normalize Edilmiş Fark Bitki Örtüsü İndeksinden (Normalized Difference Vegetation Index, NDVI) yararlanılmıştır. Nesne tabanlı sınıflandırma da en önemli aşama olan segmentasyon aşamasından hemen önce operatör tarafından girilen değerlerin doğruluğu etkilediği gözlemlenmiştir. Sonuç olarak ise binaların çıkarımının %81 oranında bir başarısı olduğu, tespit edilemeyen binaların ise küçük binaları olduğu ve bununla beraber ölçek parametresinden kaynaklandığı belirtilmiştir. Sonuç olarak hava fotoğraflarından nesne tabanlı sınıflandırma yöntemi ile otomatik nesne çıkarımının başarılı olduğu ancak SAM ve SYM verilerinin kullanılmasının doğruluğu artıracığı belirtilmiştir.

Tapan vd. (2015) çalışmalarında 30 cm çözünürlüğe sahip kızılötesi sayısal hava fotoğrafları kullanarak, ormanlık alanlardaki yolları eğitilmiş bir sınıflandırma yöntemi ile otomatik olarak belirlemeye çalışmışlardır. Çalışma alanına ait 7 adet (orman, toprak/çıplak arazi, otlak kaplı arazi, daimî araç yolu, yaz araç yolu, patika, sert zeminli yol sınıfları) eğitim sınıfı belirlemişlerdir. Eğitim alanlarının toplanmasında çalışma alanındaki detayların yoğunluğunu dikkate almışlardır. Sınıflandırma işlemi en büyük benzerlik yöntemi kullanılarak tamamlanmıştır. Sınıflandırma işlemi için piksel tabanlı sınıflandırma metodunu tercih etmişlerdir. Sınıfların doğruluk analizi, fotogrametrik yöntemlerle operatörler tarafından elle sayısallaştırılan vektör verileri kullanılarak yapılmıştır. Uygulamada, sonucu etkileyen en önemli etmenlerden birinin edinim sırasındaki görüntünün koşulları olduğu belirlenmiştir. Buna en açık örnek, görüntüdeki nesnelerin gölgeleri belirtilmiştir. Örneğin, bir ağacın gölgesindeki bir yol el ile manuel sayısallaştırıldığında operatör tarafından tanımlanabilir, oysa piksel bazlı sınıflandırmada yanlış sınıfta tanımlandığı aktarılmıştır. Uygulama alanının ormanlık alan olması ve bundan dolayı ağaçların; sıklık, seyreklik, boy vb. özelliklerinin sonucu etkilendiği tespit edilmiştir. Kızılötesi ortofoto görüntülerde yapılan piksel tabanlı sınıflandırmanın ormanlık alanlarda operatör yardımcı olabileceği ve geometrik şekli düzgün alanlarda daha anlamlı sonuçlar verebileceği değerlendirilmiştir.

Ural vd. (2015) çalışmada, bir metre çözünürlüklü renkli kızılötesi ortofoto ve hava Lidar verileri kullanarak sınıflandırma yapmışlardır. Sınıflandırma işlemi için piksel tabanlı bir yaklaşımın parçası olarak destek vektör makinesi SVM algoritması kullanılmıştır. SVM sınıflandırıcısını eğittikten sonra, çalışma alanı gridlere ayırmışlar ve her bir grid için aynı eğitilmiş modeli kullanarak sınıflandırmışlar. Sınıflandırma sonuçları daha sonra rastgele seçilen test örnekleri kullanılarak onaylamışlar. Test edilen veri kümesinin bir kısmı için karışıklık matrisine göre doğruluk analizi yapmışlar. Yol / yol dışı ikili sınıflandırma için kappa değeri 0.90 olan toplam %97,3 doğruluk elde edilmiştir.

Aggarwal vd. (2016) yüksek çözünürlüklü görüntülerden bilgi elde etmek için, bir nesnenin ve çevresinin mekânsal ve bağlamsal bilgilerini kullanmamız gerektiğinden bahsetmişler. Bu tür uzaktan algılanan verilerden bilgi elde etmek için piksel tabanlı yaklaşımlar uygulanırsa, yalnızca spektral bilgi kullanılacağından ve bu nedenle, Piksel tabanlı yaklaşımlar yüksek çözünürlüklü uydu görüntüsünün sınıflandırmasını

karşılayamayacağından söz etmişlerdir. Bu durumun üstesinden gelmek için nesne yönelimli bir yaklaşım uygulanması gerektiğinden bahsetmişlerdir. Çalışmalarında, eCognition yazılımını kullanarak nesne yönelimli bilgi kavramını göstermişler, uzamsal, spektral ve bağlamsal bilgiler gibi farklı nesne özelliklerine dayalı olarak uzaktan algılanan verilerin sınıflandırılmasını sağlamışlardır. Böylece nesne tabanlı yaklaşımla, tek tek piksel gri değerlerinden ziyade anlamlı görüntü nesneleri temelinde bilgi çıkarttıklarını aktarmışlar. Test alanında bitki örtüsü, gölge alanlar, toprak alanlar, yollar ve binalar gibi nesneler sınıflandırılmıştır. Çoklu çözünürlük segmentasyonu ve en yakın komşu (Nearest Neighbors/NN) sınıflandırma yaklaşımları kullanmışlar ve genel doğruluk değerlendirmişler. Test alanında sınıflandırılan nesneler; bitki örtüsü, gölge alanlar, toprak kısım, yollar ve binaların doğrulukları sırasıyla: 0.845, 0.890, 0.844, 0.791, 0.880 bulunmuştur.

Batur ve Maktav (2016) yaptıkları çalışmada 16 Şubat 2010 tarihinde Meriç Nehri'nde meydana gelen taşkını optik uydu görüntüleri kullanılarak incelemişlerdir. Taşkın öncesi, taşkın dönemi ve sonrasını kapsayan çok zamanlı uydu görüntüleri kullanılarak taşkın etkilediği alanları belirlemişler yine bu görüntüler yardımıyla arazi örtüsü ve taşkın haritaları oluşturmuş ve çeşitli değerlendirmeler yapmışlardır. Otomatik bir şekilde tespit ettikleri taşkın alanlarını DSİ XI. Bölge Müdürlüğü- Edirne verileri ile karşılaştırılması sonucunda %91 gibi yüksek bir doğruluk oranına sahip olduğunu belirtmişler ve optik uydu görüntülerinin taşkın çalışmalarında etkin bir şekilde kullanılabileceği göstermişlerdir.

Bulatov vd. (2016) çalışmalarında hava fotoğrafları ile elde edilen ürünleri sınıflandırarak yolları vektör hale getirmişler. Vektör yol ağları oluşturmak için beş adımlı bir prosedür sunmuşlar. Algoritmanın ana adımları; ön işleme, inceltme, çokgenleştirme, filtreleme ve genelleştirme olarak verilmiş. Özellikle, algoritmanın temelini temsil eden genelleme adımı için iki strateji sunulmaktadır. İlk strateji, köşe sayısını azaltmak için Douglas-Peucker algoritmasının değiştirilmesine karşılık gelirken; ikinci strateji, sokak sargılarının Bezier eğrileriyle daha düzgün bir şekilde temsil edilmesine dayanmaktadır. Bu durum veri kümesi için tanımlanan toplam eğriliğin azalması ile sonuçlanır. Yaklaşım farklı karmaşıklığa sahip üç veri seti üzerinde test edilmiş. Sonuçların nicel

değerlendirmesi OpenStreetMap verilerinden şekil dosyaları aracılığıyla yapılmıştır. 6 m'lik bir eşik için, %85'e kadar tamlık ve doğruluk değerleri elde edilmiştir.

Shu Z. vd. (2016) Markov rastgele alanları (Markov random field-MRF) algoritması kullanarak Lazer tarama cihazı verilerinin sınıflandırmasını yapmışlardır. MRF fonksiyonu, tekli ve çiftli potansiyellerden oluştuğundan, tek bileşenli terimlerin Destek vektör makinesi (Support vector machine-SVM) sınıflandırması ile hesaplandığından bahsetmişlerdir. Ayrıca ilk etkileşim esas alınarak sonraki sınıfların geometrik şekiller aracılığıyla işlendiğinden bahsetmişlerdir. MRF modelinin büyük ölçekli sınıflandırma çalışmalarında doğru bir şekilde işlemenin zor olduğundan bahsetmişlerdir. Büyük nesneler için segmentasyonun ihtiyaç olduğundan süper-voksel kümeleme yöntemini önermişlerdir. Ağaçlar, toprak alan ve binalar çalışma kapsamında sınıflandırılmıştır. Deneysel sonuçlara göre, bu yöntemin sınıflandırma doğruluğunu ve hesaplama hızını arttırdığını göstermektedir.

Becker vd. (2017) İHA fotogrametrisi verilerinden bina ve yol çıkarımı yapmışlardır. Çalışmalarında makine öğrenmesi ile otomatik detay çıkarma işlemi gerçekleştirmişlerdir. Ayrıca paket yazılım olan Pix4D yazılımının kendi sınıflandırmış verileri ile karşılaştırma yapmışlardır. Çalışma kapsamında, önceki nokta bulut sınıflandırma yöntemlerinden farklı olarak sadece geometrik özelliklere dayanan bilgiler kullanılmıştır. Bu çalışma için renk bilgisi olmadığından tamamen geometrik özellikler kullanmışlardır. Çalışma sonucunda, renk bilgisini kullanmanın hem niceliksel hem de niteliksel olarak performansı önemli ölçüde arttırdığını göstermişlerdir. Bunlara ek olarak renk bilgisini dâhil etmenin sınıfların tespitinde doğrulukta önemli bir artış sağladığını göstermişlerdir.

Bulatov ve Wanke (2017) havadan elde edilen görüntü verilerinden yol piksel segmentasyonu önemli ve zorlu bir süreç olduğundan bahsetmişlerdir. Sayısız özellikten hangisinin en önemli olduğunu bulmak için hem genel hem de özelleştirilmiş özelliklerle test edilen özellik seçimi için sarmalayıcı yaklaşımı önermişlerdir. Yol olma olasılığı yüksek olan pikseller ile düşük olasılıktaki pikselleri bağlayan yollar ile ilişkinin daha sonra kurulmasını içeren bir yöntem geliştirmişlerdir. Yüksek olasılıktaki pikseller filtrelendir, daha sonra düşük olasılıktaki pikseller filtrelendir ve bunlar daha yüksek dereceli klipsler olarak dahil edilir. Böylece ortaya çıkan yol ağının bağlantısını

güçlendirir. Sonuç olarak, klasik sınıflandırma ve bu yöntemin her ikisinin de avantajlı olduğundan bahsedilmiştir.

Sabuncu ve Sunar (2017) deprem sonrasında afet bölgesine ait ortofotolardan yararlanarak otomatik bir şekilde nesne tabanlı yöntem kullanarak nesne çıkarımı yapmışlardır. Uygulama kısmında kontrollü ve kontrolsüz nesne tabanlı sınıflandırma yapmışlar. Çalışma sonuçları değerlendirmişler ve karşılaştıkları sorunları paylaşmışlar.

Sameen ve Pradhan (2017) çalışmalarında, kentsel yolların çıkarılması için hava Lazer kullanılarak bulanık nesne tabanlı analiz için iki aşamalı bir optimizasyon stratejisi önermişlerdir. Yöntem, kentsel alanda doğru yol çıkarımı gerçekleştirmek için nesne tabanlı sınıflandırmanın iki temel adımını, yani segmentasyon ve sınıflandırma ile optimize çalışmaktadır. Bu hedefe, sınıf ayrılabilirliğini en üst düzeye çıkarmak için optimum ölçek parametresi ve son görüntü segmentlerini optimize etmek için optimum şekil ve kompaktlık parametreleri seçilerek ulaşılmıştır. Sınıf ayrılabilirliği Bhattacharyya mesafe algoritması kullanılarak en üst düzeye çıkarılırken, görüntü segmentasyonu Taguchi yöntemi kullanılarak en iyi hale getirilmiştir. Önerilen bulanık kuralların uygulanması diğer alanlara aktarılabilirliğinden bahsetmişlerdir. Sonuçlar bir coğrafi bilgi sisteminde manuel sayısallaştırma ile oluşturulan referans nesnelerle karşılaştırıldığında, çalışma alanında %82 genel doğruluk ve 0.79 kappa (kappa index of agreement / KIA) değeri elde edilmiştir. Geliştirilen bulanık kurallar kullanılarak yol çıkarımının doğruluğu 0.76 (üretici), 0.85 (kullanıcı) ve 0.72 (KIA) bulunmuştur. Bu arada, kurallar bir test alanına uygulandığında genel doğruluk yaklaşık %6 azalmıştır. Test alanında herhangi bir değişiklik yapılmadan aynı kurallar kullanılarak 0.70 KIA elde edilmiştir. Test alanından çıkarılan kentsel yolların doğruluğu 0.72 (KIA) olup, yaklaşık 0.16'ya düşmüştür. Önerilen yöntem, nesne tabanlı kuralları diğer alanlara aktararak uzaktan algılama yoluyla çok çeşitli gerçek uygulamalara uygulanabilirliğinden bahsedilmiştir.

Kavzoğlu ve Tonbul (2017) yaptıkları çalışmada, yüksek çözünürlüklü uydulardan elde edilen çok yüksek çözünürlüklü görüntülere yaygın olarak kullanılan iki segmentasyon uygulamışlardır. Bu iki segmentasyon, çoklu çözünürlüklü segmentasyonu ve kenar tabanlı havza dönüşümüdür. ENVI ve eCognition Developer yazılımlarını sırasıyla havza

dönüşümü ve çoklu çözünürlüklü segmentasyon algoritmalarını gerçekleştirmek için kullanmışlar. Sınıflandırma için en yakın komşu sınıflandırma yöntemini uygulamışlar ve ilgili doğruluk değerlendirmesini iki yazılım platformunda gerçekleştirmişler. Çalışma sonucunda, çoklu çözünürlüklü segmentasyonun, referans nesnelerin segmentlerinin tanımlanmasında havza dönüşümüne kıyasla daha üstün olduğunu tespit etmişlerdir. Ayrıca, çoklu çözünürlüklü segmentasyon kullanılarak daha yüksek sınıflandırma doğrulukları elde ettiklerine değinmişlerdir.

Widyaningrum ve Lindenbergh (2019) çalışmalarında hava Lazer nokta bulutundan ve ortofotodan alınan renk bilgileriyle birleştirilmiş yol ağını çıkarmak için bir metodoloji sunmuşlardır. Çalışmaları, yol ağlarının iskelet tabanlı çıkarımını kapsamaktadır. İlk olarak, zemin noktalarını zemin dışı noktalardan ayırmışlar. Ardından, filtrelenmiş toprak noktalarını Rastgele Orman (Random forest/RF) algoritmasını kullanarak yola ve yol dışı noktalara göre sınıflandırmışlar. Yol segmentinin iskeletlenmesi için bir yöntem olan paralel inceltme, sınıflandırılmış yol noktalarının yoğunluk haritası olarak çıkarılan ikili bir görüntü üzerinde gerçekleştirilmiştir. Son olarak, yol merkez hattı önerilen topolojik düzen ve düzenlenme yaklaşımımızla elde edilmektedir. Önerilen yöntemi ISPRS karşılaştırma verileri üzerinde test edilmiştir. Çalışma alanındaki %95'ten fazla yol çıkarıldığı için iskelet tabanlı karayolu ağ çıkarımı umut verici bir yöntemdir. Gelecekte, daha düzgün bir hat temsili elde etmek için iskeletin düzenli hale getirilmesi hala gerekli ama zorlu bir araştırmadır. Ayrıca çalışmalarında; RF sınıflandırma sonuçlarının, RGB (Red-Green-NIR) ve yoğunluk özelliklerinin birleşiminin yalnızca RGB kullanmaktan daha iyi doğruluk sağladığını göstermektedir. Sadece yoğunluk kullanan çalışma alanının RF sınıflandırma sonucunun genel doğruluğu %81.03 iken RGB özellikleri ile kombinasyon %91,91 hesaplanmıştır.

3. GÖRÜNTÜ SINIFLANDIRMA ve DETAY ÇIKARMA YÖNTEMLERİ

Bilginin doğrudan gerekli olduğu uygulamalarda doğru bilgiyi hızlı bir şekilde elde etmek uygulamanın maliyetini ve güncelliğini doğrudan etkiler. Günümüz teknolojileri sayesinde bilgi toplama çok daha kolay hale gelmiştir. Araziden toplanan bilgiler çok yoğun ve karmaşık veriler içermektedir. Bilgiye ulaşmanın hızlılığı kadar yoğun bilgi karmaşıklığından istenilen bilgiyi ayırt etmekte bir o kadar önem arz etmektedir. Birçok mühendislik alanına altyapı olarak hizmet veren harita mühendisleri, teknolojinin getirdiği imkânları etkin bir şekilde kullanarak uzaktan algılama ve hava görüntü verilerini veri toplama metodu olarak yoğun bir şekilde kullanmaktadırlar. Bu yoğun verilerden detay çıkartımı hız ve maliyet açısından önemli bir noktaya ulaşmıştır.

Detay çıkartımı; görüntü verilerindeki farklı nesnelerin karakteristik özelliklerini kullanarak gruplandırma ya da sınıflandırma işlemlerinin bütünü olarak ifade edilebilir. Bu ayırt edici karakteristik özellikler; renk, doku, şekil veya konum, en yakın komşuluk, yoğunluk gibi nesnenin genel özellikleri olabilir (Vosselman vd. 2004). Görüntü sınıflandırma işleminin birincil amacı, görüntüdeki tüm pikselleri otomatik olarak zemin örtüsü sınıflarına veya temalarına göre gruplamaktır. Genel olarak sınıflandırma, çıkartımı istenen nesnelerin sınıf tanımlarına göre belirli bir sınıf kategorisine dâhil etmek anlamına gelir. Bu nedenle bir sınıf tanımı, istenen sınıfın tipik özelliklerinin ve koşullarının bir tanımıdır. Nesneler daha sonra bu özelliklere veya durumlara uyup uymadıklarına göre istenilen sınıfa dâhil edilir.

Detay çıkarımının amacı, görüntüdeki nesneleri istenen amaca göre elde etmektir. Bu edinimin sonucu, resimler/görüntü veya simgeler şeklinde olabilir. Bu tanımlamaya dayanarak kendi içinde temel bir konu olmasına rağmen aynı zamanda fotogrametri; sayısal görüntü işleme ve bilgisayarlı görüntülemenin alt konusu olarak da değerlendirilir. Sayısal görüntünün bilgisayarlı görüntüleme ile nasıl ifade edileceği açıkça netleşmiş olur. Sayısal görüntü işleme tekniklerinin gelişmesiyle birlikte detay çıkarma da kullanılan teknikler hızla değişiyor. Literatürdeki detay çıkartımı çalışmaları farklı sınıflandırma yöntemleri ile yapıldığı görülmektedir. Bu nedenle detay çıkarma için belirli kriterler uygulanmalıdır. Förstner ve Gülch'e göre bu kriterler değişmezlik, tutarlılık ve yorumlanabilirlik olmak üzere üç ana nokta temel alınmıştır (Förstner ve Gülch 1987). Bu yüzden detay çıkarma çalışmalarında; nokta, çizgi ve bölgesel

(mekânsal) olmak üzere 3 temel çıkartım üzerine yoğunlaşmalar görülmektedir.

Otomatik sınıflandırma verilen bir nesne kümesi içinde benzer özellikleri kullanılarak, nesnelerin homojen sınıfları oluşturması için matematik ve istatistik yöntemler ile gerçekleştirilen otomatik bir işlemdir. Sınıflandırma yöntemi ile daha anlamlı ve sorgulanabilir nesnelerin çıkarılması sağlanır (Elberink 2010). Genellikle, örnek tabanlı sınıflandırma ve bulanık küme sınıflandırıcıları ile sınıflandırma yöntemleri tercih edilmektedir. Örnek sınıflandırma yöntemi en yakın komşu yöntemidir. Sınıfı bilinen yeterince örnek piksel ya da bunlarla ilgili olasılık dağılım bilgisinin bulunmadığı durumlarda, kümeleme denen yöntemler kullanılır. Spektral olarak ayrılabilen sınıflar belirlenir ve bu sınıflara ait bilgi tespit edilir. Sınıflandırma yöntemi kontrollü ve kontrolsüz sınıflandırma şeklinde iki gruba ayrılır ve veri işleme yöntemlerine göre; piksel ve nesne tabanlı sınıflandırma şeklinde iki başlıkta toplanır.

3.1 Piksel Tabanlı Sınıflandırma Yöntemi

Piksel tabanlı sınıflandırma, 1970'li yıllarda çok bantlı görüntülerin işlenmesiyle ilk kez geliştirilmeye başlanmış bir yöntemdir (Nixon ve Aguado 2008). Nesnelerin yansımaya değerleri kullanılarak sınıflandırma yapılmaktadır. Bir pikselin ait olduğu sınıfa atama işlemi o piksele ait görüntü üzerindeki spektral yansımaya değerine göre yapılır. İstatistiksel olarak her piksel benzer karakteristik özellik taşıyan gruba atanmaktadır.

Klasik piksel-tabanlı sınıflandırma yaklaşımlarının bütün amacı, arazi örtü sınıfları ve özelliklerine göre bir görüntüdeki tüm pikselleri otomatik olarak bir araya getirmektir.

Piksel tabanlı sınıflandırmanın beş tipi vardır. Çalışmanın amacına uygun olarak bu yöntemlerden birisi seçilir. Amaca uygun spektral bantların ve uydu görüntüsünün seçilmesi yapılacak sınıflandırmanın doğruluğunu artıracaktır. Elde edilecek sonuç, yeteri miktarda kontrol noktasının seçilmesine ve uygun sınıflandırma algoritmalarının belirlenmesine bağlıdır. Şekil 3.1'de klasik piksel tabanlı sınıflandırma yöntemleri gösterilmiştir.



Şekil 3.1 Piksel tabanlı sınıflandırma yöntemleri.

3.1.1 Kontrolsüz Sınıflandırma Yöntemi

Kontrol bölgeleri kullanılmadan yapılan sınıflandırma işlemidir. Piksellerin kullanıcı müdahalesi olmaksızın otomatik olarak kümelendirilmesi temeline dayanmaktadır. Bu yöntem karar kuralı olarak minimum uzaklığı kullanır. Kontrolsüz sınıflandırma; görüntüdeki veri tanımlanamadığında başvurulacak bir yöntemdir. Bu yöntemde, arazi örtüsü tipinin bilinmesine gerek yoktur. Sınıf sayıları kullanıcı tarafından belirlenir sonrasında benzer pikseller sınıflandırma programı tarafından bir araya getirilir.


3.1.2 Kontrollü Sınıflandırma Yöntemi

Görüntüden hangi sınıfların elde edilmek istendiği önceden belirlendiği ya da bilindiği için, görüntüden istenilen sınıflara ait denetim alanları seçilir. Bu seçim için gerekirse arazi ölçümü yapılır. Sınıflandırmanın doğruluğu kontrol alanlarının seçimiyle doğrudan ilişkilidir. Sınıflandırmada en çok kullanılan istatistiksel yöntemler Minimum uzaklık (Minimum Distance), Paralelkenar/Paralelyüz Yöntemi (Parellelepiped) ve maksimum benzerlik (Maksimum likelihood)'dir.

3.1.2.1 Minimum uzaklık (Minimum Distance)

Her sınıf için tüm bantlardaki ortalama spektral değerleri hesaplanır. Bilinmeyen olarak tanımlı bir piksel, kendi değeri ile her bir sınıf ortalaması arasındaki uzaklığın (Euclid mesafesi) hesaplanması yoluyla sınıflandırılır (Şekil 3.2). Her piksel kendisine en yakın ortalama vektöre sahip sınıfa atanır. Matematiksel olarak kolay ve hesaplama açısından basit olan bu yöntem spektral cevap verisinde farklı düzeydeki varyanslara duyarlı


değildir. Bu sebepten dolayı birbirine yakın ve yüksek varyansa sahip uygulamalarda daha yaygın kullanılır (Ayhan vd. 2003).



Şekil 3.2 Minimum uzaklık yöntemi (Ayhan vd. 2003).

3.1.2.2 Paralelkenar/Paralelyüz Yöntemi (Parellelepiped)

Her sınıf için görüntüdeki sınıf yansıtım değerlerine dayalı parlaklık değerlerinin alt ev üst sınırları tespit edilir. Sınırlar arasındaki yansıtım değerlerine sahip olan hücreler önceden belirlenmiş sınıfına atanır (Şekil 3.3). Bir piksel karar bölgelerinin dışında kalması durumunda bilinmeyen olarak sınıflandırılır (Ayhan vd. 2003). Basit bir algoritmaya sahip olan bu yöntem yüksek performans gösterir ancak birden fazla sınıfın karar bölgesi içinde kalan ya da karar bölgelerine giremeyen ve bilinmeyen olarak atanan pikseller, yöntemin doğruluk derecesini azaltacaktır.




Şekil 3.3 Paralelkenar yöntemi (Ayhan vd. 2003).

3.1.2.3 Maksimum benzerlik (Maksimum likelihood)

Bir piksel en yüksek olasılık değerine sahip olduğu sınıfa atanır. Bu olasılıkların hesaplanabilmesi için bir olasılık dağılım modeline ihtiyaç vardır. Uygulamada genellikle normal dağılım modeli kullanılır. Her bir sınıf eğitim verisinin normal dağılım gösterdiği kabul edilir. Gerçekte bu kabul doğru olmamasına rağmen özellikle optik uzaktan algılama verilerinin modellenmesinde, Normal dağılımın uygun olduğu ve bu kabule dayanan sınıflandırma algoritmalarının daha sağlam algoritmalar oldukları görülmüştür. Normal dağılım tek değişken için ortalama ve varyans parametreleri ile çok değişkenli veri için ise ortalama vektörü ve kovaryans matrisiyle belirlidir (Sunar 2011).

Şekil 3.4'de görüldüğü gibi, her hücrenin belirlenen sınıflara ait olma olasılığı hesaplanarak elde edilen en yüksek olasılığa hücrenin atanması sağlanır. Diğer yöntemlere göre daha doğru sonuçlar vermesine rağmen, karmaşık algoritması yüzünden daha yavaş çalışır



Şekil 3.4 Maksimum benzerlik yöntemi (Ayhan vd. 2003).

3.1.2.4 Melez (Hibrit) Sınıflandırma Yöntemi

Melez sınıflandırma kontrollü ve kontrolsüz sınıflandırmanın doğruluğunu artırmak ya da daha verimli kılmak amacıyla geliştirilmiştir. Örneğin kontrollü sınıflandırmada ayırt edilecek sınıfları temsil etmek üzere sınıfların belirlenmesinde analiste yardımcı olması maksadıyla kontrolsüz örneklem alanlarının sınırları görüntüde çizdirilebilir. Kontrolsüz eğitim alanları, kontrollü eğitim alanlarından kasten çok farklı olacak şekilde seçilen görüntü alanlarıdır.

Melez sınıflandırıcılar özellikle tekil örtü tipleri için spektral cevap paternlerinde karmaşık değişebilirliklerin olduğu analizlerde kullanılabilir. Bu tür durumlar bitki örtüsü haritalaması gibi uygulamalar da oldukça yaygındır. Bu durumda örtü tiplerindeki spektral değişkenlik normalde hem örtü tipleri içindeki değişimden hem de farklı bölge şartlarından kaynaklanmaktadır. Rehberli kümeleme bu tür durumlarda oldukça etkin olduğu görülmüş melez bir yaklaşımdır.

3.1.2.5 Spektral Karışım Analizi Sınıflandırma Yöntemi

Karışık piksellerin sınıflandırılması genellikle karışık pikseller algılayıcısı olan IFOV'unun yeryüzünde birden fazla yer örtü tipi içermesi durumunda oluşmaktadır. Görüntüdeki karışık pikseller, görüntüyü elde etmekte kullanılan uzaktan algılama sisteminin mekansal çözünürlüğü ve incelenen yüzey özelliklerinin mekansal ölçeğinin bir fonksiyonudur. Spektral karışım analizi ve bulanık (fuzzy) sınıflandırma, karışık piksellerin sınıflandırması ile ilgilenmek için tasarlanmış iki işlemdir. Piksel-altı sınıflandırma bu yöntemlerle başarılı sonuç verebilir.

Spektral karışım analizi, karışık örneklem alanların referans verisi ile karşılaştırıldığında kullanılan teknikleri içermektedir. Belirli yüzey özelliklerinin sebep olduğu, görüntüdeki spektral farklılıktan kaynaklanan bir kestirim şeklinde düşünülebilir. Sonuç olarak referans verideki piksellerin yeryüzünde kapladığı alanların yaklaşık oranlarının bir tahmininden oluşmaktadır.

Spektral karışımın analizi, arazi örtüsü sınıflandırması için kullanılan diğer görüntü işleme yöntemlerinden biraz farklıdır. Kavramsal olarak, farklı spektral cevap paternlerinin karışımının fiziksel bir modeline dayalı olduğu için bu bir istatistiki değil, deterministik bir yöntemdir. Ayrıca, sınıflandırılacak olan sınıflar sadece piksel içinde algılandığı için kullanışlı bilgiyi piksel-altı düzeyinde sağlar. Birçok arazi örtü tipi iyi bir mekansal ölçekten görünseler bile heterojen karışımlar olarak görülmeye eğilimlidirler. Bu nedenle, bu yöntem her piksele dominant sınıfın atanmasıyla elde edilene göre daha iyi bir şekilde yüzeyin olması gereken yapısını daha gerçekçi yansıtır.

Örneğin dört-bantlı bir SPOT HRVIR çok spektrumlu görüntüsünün spektral karışım analizi, beş farklı ideal üye sınıfın kesirli oranlarının kestirimini bulmada kullanılır. Bu işlem; dört, üç veya iki ideal üye sınıfı içinde yapılabilir. Bu görüntü tek başına ek bilgi

olmaksızın beş ideal üye sınıftan fazlası için kesirli sınıf tahminlerini çıkarmak amacıyla doğrusal spektral karışım analizinde kullanılamaz.

3.1.2.6 Fuzzy (Bulanık) Sınıflandırma Yöntemi

Fuzzy sınıflandırma, karışık-piksel problemini bulanık mantıkla çözmeye çalışır. Burada verilen bir varlık birden fazla kategoride kısmi üyeliğe sahip olabilir. Bulanık sınıflandırmaya bir yaklaşım da bulanık kümelemedir. Bu işlem kavramsal olarak daha önce tanımlanan “K-ortalamlar” kontrolsüz sınıflandırması yaklaşımına benzerdir. Fark, spektral ölçüm uzayında sınıflar arasında “keskin” sınırlar almak yerine bulanık bölgeler kurulur. Bu nedenle, sırf tekil sınıfa atanan her bir bilinmeyen ölçüm vektörü yerine, o ölçünün ölçüm uzayındaki bir bölünmeye ne kadar yakın olduğuna bakılmaksızın üyelik derecesi değeri kullanılır. Bu değer bir piksel ölçüsünün bütün sınıfların ortalamalarına ne kadar yakın olduğunu tanımlamak için atanır. Fuzzy sınıflandırmaya diğer bir yaklaşım, fuzzy kontrollü sınıflandırmasıdır. Bu yaklaşım en yüksek olabilirlik sınıflandırmasına benzerdir; farklılık, fuzzy ortalama vektörleri ve kovaryans matrisleri istatistiksel ağırlıklı eğitim verisinden geliştirilir. Tamamen homojen olan eğitim alanlarının sınırlarını çizmek yerine, sürekli ve karışık eğitim alanlarının bir kombinasyonu kullanılabilir.

Değişik özellik tiplerinin bilinen karışımları ile fuzzy eğitim sınıfı ağırlıkları belirlenir. Bundan sonra sınıflandırılmış bir piksel üyelik derecesine atanırken onun her bir bilgi sınıfındaki üyeliğini kullanır.

3.2 Nesne Tabanlı Sınıflandırma Yöntemi

En yaygın kullanılan sınıflandırma yöntemi piksel tabanlı sınıflandırmadır. Son yıllarda, klasik piksel tabanlı sınıflandırma yöntemlerinin dışında nesne tabanlı sınıflandırma da kullanılmaya başlanmıştır. Yapılan çalışmalarda, nesne tabanlı sınıflandırma sonuçları piksel tabanlı sonuçlara göre daha başarılı olmasından dolayı klasik yöntemlerdeki sorunları çözmek adına umut veren bir yöntem olarak görülmeye başlanmıştır (Rottensteiner vd. 2012).

Nesne tabanlı görüntü analiz yöntemi; görüntüdeki şekil, renk, doku vb. ayırt edebilecek özellikleri dikkate alarak nesneleri yakalamaya yönelik bir sistem öngörür. Bu sistem ile görüntüdeki bina, ağaç, araba gibi farklı nesneleri ayırt edebilme imkânı sunmaktadır.

Nesne tabanlı sınıflandırma yöntemi segmentasyon ve sınıflandırma aşamalarından oluşmaktadır. Segmentasyon yöntemi ile görüntü hedef sınıfların aynı segmentlerde toplanmasına olanak sağlarken, ikinci aşama olan sınıflandırma ile nesneler sınıf haline dönüştürülür.

Nesne tabanlı sınıflandırma yaklaşımına göre bir nesne; benzer spektral ve mekansal özelliklere sahip bir piksel grubu olarak tanımlanır. Bu yaklaşımda, nesneleri temsil eden segmentler; şekil, doku, komşuluk ilişkisi, morfolojik ilişkiler, alan, yükseklik değeri, mesafe, geometrik şekil, standart sapma, yoğunluk vb. değerleri kullanılarak analiz edilir ve hedef sınıflara atanır. Bu bilgilerin çoğu nesne tabanlı sınıflandırma yöntemine özgüdür, piksel tabanlı sınıflandırma yönteminde kullanılamazlar. Nesneye ait farklı özellikler kullanılarak daha doğru sınıflandırma sonuçları elde edilir (Hofmann ve Jain 1987). Bu sebeple, klasik yaklaşım olan piksel-tabanlı sınıflandırmanın yanında, nesne-tabanlı sınıflandırma yaklaşımları kullanımı gün geçtikçe artmaya başlamıştır. Bunun önemli nedenlerinden biride, yüksek çözünürlüklü görüntülerde mevcut olan zengin bilgi içeriğinin piksel-tabanlı sınıflandırma yaklaşımları sonucunda tam olarak yansıtılamaması olarak gösterilir (Navulur 2007). Ayrıca, klasik yöntemler ile yapılan çalışmalarda; ağaçlar ve binaların karışması, gölgelerin yanlış sınıf grubunu ifade etmesi, yollar ve çatıların karışması gibi karmaşık sorunlar ile karşılaşmaktadır.

Örneğin; nesne tabanlı yaklaşım ile oluşturulan belirli sayıda poligonlar ile sınıf belirlemek, piksel tabanlıda yüzlerce piksel değeri ile karşılaştırıldığında, nesne tabanlı sınıflandırma çok daha hızlı ve doğruluğunun değeri yüksek sonuç vermektedir (Navulur 2007). Doğruluk değerinin yüksek olması, nesnelerin aynı sınıfa dahil edilirken sadece gri değerlere göre değil, nesnenin sahip olduğu birden çok özelliğinin dikkate alınarak aynı sınıfa dahil edilmesinden kaynaklanmaktadır. Nesnelerin ortalama değer ve standart sapma gibi farklı spektral özelliklerinden yararlanarak nesne özelliklerinin varyasyonları yakalanmaktadır. Konum özellikleri dikkate alınarak; alan, uzunluk, sınır kalınlığı, yükseklik, eğim analizi ve yön parametrelerinden yararlanılarak nesne çıkarımı gerçekleştirilmektedir (Çelik 2006).

Nesne-tabanlı sınıflandırma yaklaşımının temel işlem birimi, alışlagelmiş ve klasikte kullanılan piksel-tabanlı görüntü analizinin tersine tekil piksel değil, görüntü segmentleri veya nesneleridir. Burada sınıflandırma işlemi görüntü nesneleri üzerinden yapılır.

Nesne-tabanlı yaklaşıma bir sebep, çoğu görüntü analizi uygulamasından beklenen sonucun, gerçek dünya nesnelerinin, gerçek sınıflandırma ve gerçek şekillerinde olmasıdır. Bu beklenti alışılabilir piksel tabanlı yaklaşımlarla sağlanamaz (Hofmann 2001a, b, c). Direkt olarak sunulan nesne yoluyla edinilen görüntü bilgisi, bu görüntü nesnelerinin birbirine bağlanmasıyla oluşur. Hâlbuki tekil, komşu piksellerin topolojik ilişkisi üstü kapalı olarak sayısal veride verilir, böylece komşu nesnelerin çıkarımı için komşu piksellerin bir arada açık bir şekilde ele alınması gerekir. Sonuç olarak, topolojik ağ çok farklı çeşitte komşuluk bilgilerinin etkin bir biçimde yayılımına izin veren büyük bir avantaj sağlar. Her sınıflandırma işlemi kesin bir ölçeğe bağlıdır. Bu nedenle, görüntü nesnelerinin ortalama çözünürlüğünün istenilen ölçeğe uygunluğu çok önemlidir. Görüntü bilgisi, görüntü nesnelerinin ortalama büyüklüğüne bağlı olarak farklı ölçeklerde sunulabilir. Aynı görüntü daha küçük veya daha büyük nesneler olarak segmentlere ayrılabilir ki bu görüntü nesnelerinden türetilen tüm bilgileri pratik olarak büyük ölçüde etkiler. Bu nedenle her ölçekte farklı bilgiler çıkarılabilir. Bu bilgileri farklı nesne tabakalarında eş zamanlı olarak farklı ölçekteki görüntü bilgileri gibi sunmak mümkündür. Bu yapıdaki nesne tabakaları birbirleriyle ilişkilendirilerek, birçok ek bilginin çıkarımına katkıda bulunulabilir (Marangoz vd. 2004). Buna, örneğin hiyerarşik ağ düzeniyle ve nesnelerin bu ağ yapısındaki sunumuyla varılabilir. Komşularının yanında böyle düzenli bir hiyerarşik yapıda nesneler, alt ve üst nesnelerini de tanırlar. Bu, belirli bir alanın; alt nesnelerin hassas analizine olanak tanır ve böyle düzenli bir hiyerarşik yapı olmadan bu tip sonuçlara ulaşmak imkânsızdır. Bundan başka, alt nesnelerin yapısına bağlı olarak üst nesnelerin şekilleri değiştirilebilir. Tekil pikseller veya tek pikselden oluşan nesnelerin, görüntü nesnelerinin özel bir durumu olduğu göz önüne alınmalıdır. Bu, en küçük işlem ölçeğini ifade eder. Nesne tabanlı görüntü analizinin şaşırtıcı özelliklerinden biri, çok sayıda ek bilginin görüntü nesnelerinden çıkartılabilmesidir. Bunun arkasında yatan; şekil, doku, komşuluk ve diğer nesne tabakalarından gelen bilgilerdir. Bu bilgiler kullanılarak, sınıflandırma, daha iyi semantik ayırım ve daha doğru sınıflandırma sonuçlarına ulaşılabilir. Baatz vd. (2004) kavramsal bakış açısıyla, mümkün olan özellikleri aşağıdaki şekilde gruplara ayırmışlardır:

- Temel Özellikler: Nesnelerin fiziksel özellikleri, gerçek dünyanın resmedilmesiyle ve görüntüleme durumuyla belirlenir (basit olarak sensör ve aydınlatma). Bu özellikler rengi, dokuyu ve nesnelerin yapısını ifade eder.

- Topolojik Özellikler: Nesneler veya bütün çerçevenin geometrik komşuluğunu ifade eden özelliktir. Örneğin solda, sağda olma veya belirli bir nesneye belirli bir mesafede olma veya görüntü içindeki belirli bir alanda olma.
- Çevresel Özellikler: Nesnelerin semantik komşuluk ilişkilerini tanımlayan özelliklerdir. Örneğin bir park %100 şehir alanıyla çevrili olmalıdır.

Sınıflandırmanın temelinde, görüntü nesnelerinin işlenmesi özel yollardan yapılabilir. Bir görüntünün tüm alanlarını aynı algoritmayla işlemek yerine, değiştirilmiş bir işlem uygulamak çok daha uygun olacaktır. Bu nesne tabanlı görüntü analizinin öne çıkan özelliklerinden biridir. Nesne tabanlı yaklaşımın karakteristiği, görüntü nesnelerinin işlenmesi ve sınıflandırılması arasındaki döngüsel ve karşılıklı etkileşimdir. Segmentasyona, ölçeğe ve görüntü nesnelerinin şekillerine bağlı olarak sınıflandırma için özel bilgiler mevcuttur. Tam tersine, sınıflandırmaya bağlı olarak özel algoritma işlemleri aktif hale getirilebilir. Çoğu uygulamada istenilen coğrafi bilgi (geoinformasyon) ve ilgilenilen nesneler, sınıflandırma ve işlemlerin iteratif döngüsüyle adım adım çıkarılabilir. Böylece, işlem birimi olan görüntü nesnelerinin, şekilleri, sınıf atamaları ve karşılıklı ilişkileri sürekli olarak değişmiş olur.

İnsanların görüntü anlama işlemine benzer olarak, bu çeşit döngüsel bir işlem, sınıflandırmada bir öncekinden daha farklı sonuçlar doğurur ve orijinal görüntü bilgisinin en doğru biçimde çıkarımını sağlar. Ayrıca her adımda üretilen bu farklı yeni bilgi ve malumatlar analizin diğer adımlarında yararlı bir şekilde kullanılabilir. Böylece çıkarım, sadece görüntü nesnelerinin şekil ve boyutlarıyla ilgilenmekle kalmaz onların semantik bilgilerini de işlem içerisine katar. Bu şekildeki döngüsel bir işlemle, görüntü alanındaki piksellerin sadece uzaysal kümeleşmesi gerçekleştirilmez aynı zamanda görüntünün bilgi içeriğinin uzaysal ve semantik yapısına yaklaşılr ki bu noktada asıl önemli olan da gerçek dünya nesnelere yaklaşımdır. İlk adımlarda çıkarılan veri çok fazla fakat anlam ifade etmezken, gerçek anlamda bilgi ve semantik farklılıklar uygulamanın ileriki adımlarında oluşmaya başlar. Sonuç olarak sınıflandırılmış görüntü nesnelerinin ilişkilendirilmesi, uzaysal veya semantik ağ olarak görülebilir. Bu noktadaki en önemli husus bu şekilde bir ağ yapısının kurulmasıyla birlikte ek bilgilerin bu ağ üzerinden çıkarımının düzgün yapıdaki analizler yardımıyla oldukça basit bir şekilde yapılabilmesidir.

Nesne tabanlı yaklaşım, sonuçları birbirlerini etkilese de pratikte birbirinden bağımsız olarak uygulanan özel segmentasyon ve sınıflandırma teknikleridir. Örneğin, sınıflandırmaya esas olan yapı, segmentasyon sonucunda oluşan nesnelerdir. Ancak iki aşama kesinlikle yapılırken birbirlerine bağlı değildir. Bununla beraber, bu iki ayrık uygulama içinde kullanılacak işlem yöntemlerinin doğru seçimi, uygulamaya güç katabilir ve doğru bir segmentasyon ve sınıflandırma yöntemi, kullanıcıya yaklaşımın tüm avantajlarını sağlar (Baatz vd. 2004).

3.2.1 Görüntü Yorumlamada Temel Bileşenler

Burada, nesne-tabanlı sınıflandırmanın en önemli özelliği olan görüntü yorumlamada ölçek ve görüntü semantikleri konuları incelenmiştir.

3.2.1.1 Görüntü İşlemede Yaklaşık Ölçek

Ölçek, görüntüyü anlamının önemli adımlarından biridir. Uzaktan algılama ve CBS için, günümüzde çok fazla kaynak bulunmaktadır. Her ne kadar uzaktan algılama alanında, ölçek piksel çözünürlüğü olarak kabul edilse de ilgi konusu istenilen nesneler çoğu zaman kendi yapılarından gelen ölçeğe sahiptirler. Ölçek belirli bir nesne sınıfının oluşmasını veya oluşmamasını belirler. Buna karşın sınıflandırma işi ve her bir nesne, direkt olarak ilgilenilen nesnenin ölçeğini belirler.

Ölçek ve çözünürlük arasındaki farklar: Çözünürlük genellikle bir pikselin yerde kapladığı alanı ifade ederken; ölçek, belirli bir olgunun tanımlanabildiği çıkarım büyüklüğünü veya seviyesini tanımlar. Bu nedenle bir görüntüyle farklı çözünürlükler yerine farklı ölçeklerde çalışmak analizi kolaylaştırır. Konu ile ilgili uzaktan algılama örnekleri, kentsel alanlar ve ekosistemlerdir. Bir şehrin yüksek çözünürlüklü görüntüsüne bakıldığını varsayalım. Çok yakından bakıldığında tekil evler, binalar, yollar ve diğer kentsel nesneler ayrıntılı biçimde görülecektir. Eğer bakış mesafesi büyütülürse, bu kez tekil binalar görülmez, fakat oldukça farklı konut bölgeleri veya mahalleler ayırt edilebilir. Farklı dokular, farklı boyut ve şekilleriyle de seçilebilirler. Mahalle dokusu daha büyük bir ölçekte onun alt nesne ve yapılarını içerir (örn. Evler, yollar, bahçeler) ve bunlar özellikle renk tonu, şekil ve ayrıca topolojik ilişkileriyle tanımlanır.

Bir görüntüyü duvara yerleştirdiğimizde birkaç adımlık mesafeden, gözlemlerle şehrin kendisini ve belki onu çevreleyen tarım alanlarını ve ormanı fark edebilirsiniz. Çevreleyen tarımsal alanlar ve ormanların şehirle kıyaslanabilir büyüklükte olduğunu görebilirsiniz. Şehirlerin, ormanların ve tarım arazilerinin benzer ölçekte olduğunu kabul etmeliyiz. Farklı büyüklük ele alınırsa, aynı şey evler ve ağaçlar için de geçerlidir. Özet bir kabulle, eş zamanlı olarak yapıların farklı ölçeklerde olması, doğadaki ve ayrıca görüntüdeki fraktal geometrinin ve topolojinin bir sonucudur. Ortaya çıkartılan farklı olgularda ve gerçek dünya nesnelerinin yapılarında bir çeşit hiyerarşi vardır. Bu hiyerarşi açıkça ölçekle belirlenir. Örneğin evleri, binaları, yolları çıkartırsak bunların birleştirilmesiyle yerleşim alanlarını, mahalleleri çıkartmış oluruz. Bunun gibi birçok yerleşim bölgesinin birleşimiyle kasaba veya şehir yapısına ulaşırız. Ekosistemler buna benzer örnekler gösterirler: Birkaç ağacın birleşimi bir grup ağaç oluşturur ve daha çok ağacı birleştirmek ya da birçok grubu birleştirmek bir ormanı oluşturur.

Ormanlar ve kasabalar benzer çıkarım düzeyi gösterirler. Her ikisi de kıyaslanabilir ölçektedir ve her ikisi de yüksek semantik çıkarımdadır. Etkilenen nesne sınıfları arasındaki hiyerarşik ölçek ilişkileri açıktır: Örneğin mahalleler şehirlerin alt yapılarıdır ve evler de mahallelerin alt yapılarıdır. Bu hiyerarşik ölçek ilişkileri, gerçek dünya yapılarının gözlemlerinde ve tanımlanmalarında üstü kapalı olarak kendiliğinden verilir. Yine de bunun tersine, özellikle bu örneklerin açık bir şekilde sunumu, otomatikleştirilmiş görüntü yorumlama tekniklerine değerli katkılar sağlayabilir. Basitçe, evlerin kentsel alanlardaki sınıflandırma olasılığı, ormanda olmaları durumuna göre çok daha yüksektir. Bu nedenle bir görüntüyü başarılı bir şekilde analiz etmek için onun bilgi içeriğini birkaç farklı ölçekte eş zamanlı sunmak ve sonuç ürünler arasındaki farklı ölçek ilişkilerini ortaya çıkartmak gerekir (Baatz vd. 2004). Bu bağ ve ilişkilerin, sadece görüntünün çözünürlüğünü değiştirerek analiz edilemeyeceğini gösterir. Bu husus birçok faydalı bilginin kaybolmasına da neden olabilir.

3.2.1.2 Görüntü Semantikleri – Görüntü Nesneleri Arasındaki Karşılıklı İlişkiler

Görüntüyü anlamadaki en önemli durumlardan biri, kontekst hakkındaki bilgidir. İki tür kontekstsel bilgi vardır: Görüntünün durumunu (basit olarak zaman, sensör ve konum bilgileri) tanımlayan global kontekst ve görüntü bölgelerinin karşılıklı ilişkilerini veya karşılıklı anlamlarını tanımlayan lokal kontekst. Kontekst bilgiyi işlemek her zaman

bilinçli veya bilinçli olmadan insan algısında mevcuttur ve onun büyük kabiliyetine katkıda bulunur. Anlamli kontekst bilgisi almak için, doğru ölçekteki görüntü alanları ilişkilendirilmelidir. Bu ölçek sınıflandırma işlemi ile görüntü verisinin çözünürlüğünün entegrasyonu ile kararlaştırılır.

Örnek olarak, çok yüksek çözünürlüklü bir görüntüde parkları ayırt etmek için sınıflandırma işlemi hayal edelim. Bir park her zaman geniş ve birbirini takip eden yeşil alanlardan oluşur. Bu farklı ölçek, parkı bahçeden ayırır. Ek olarak, parklar da örneğin parkların kentsel alanda yerleşmesiyle çayırırlardan ayrılır. Tekil komşu evler parkları tanımlamak için yeterli bir şart değildir. Yine de tekil binalara komşuluğu bahçeleri, çayırdan ayırmak için uygun bir ölçüttür. Bu basit örnek zaten ne kadar çok, birbiriyle ilişkili olan yapıların ölçeklerine bağlı kontekst bilginin mevcut olduğunu gösterir. Bu şaşırtıcı gerçek, anlamli kontekst ilişkilerinin piksel tabanlı yaklaşımları kullanarak tanımlamanın ne kadar zor veya hatta imkânsız olduğunu açıklar. Sadece uygun ölçekteki görüntü nesnelere bağlı görüntü bilgisini sunmak, görüntü semantiğinin ele alınmasını sağlar. Ek olarak, görüntü nesnelerinin uzaysal kontekstinden haberdar olmalarını sağlamak için, onları ilişkilendirmek gerekir. Bu nedenle bir topolojik ağ yaratılır. Aynı konumdaki, farklı ölçekteki görüntü nesneleri bağlandığı zaman, bu ağ hiyerarşik olur. Böylece her nesne onun komşusunu, alt ve üst nesnelerini bilir. Bu ayrıca hiyerarşik ölçek ilişkilerinin tanımına izin verir. Sınıflandırmayla ve sınıflarla nesneler arasındaki karşılıklı bağlar ile böyle bir ağ uzaysal semantik ağ olarak görülebilir. Şu bir gerçektir ki; her zaman görüntü semantikleriyle uğraşmak anlamına gelen görüntü anlama, özellikle uzaktan algılama alanında sayısal görüntü işleme kapasitesiyle yeterince örtüşmemektedir.

Uzaktan algılama bilgilerini çıkarmadaki şüphe ve çeşitli belirsizlikler, uzaktan algılama verisinden çıkarılacak bilgiyi etkiler. Her şeyin başında, aynı algılayıcıdan gelse bile, çerçeveden çerçeveye değişen, veri kazanım işlemlerini, veri işlemeyi ve veri üretimini etkileyen birçok faktör vardır. En basitinden, dünya gözlem verilerinin doğasından gelen problem, yer örtüsünün mevsime, günün zamanına, ışık durumuna ve hava durumuna göre farklı görünebilmesidir. Ayrıca, aynı çeşit nesneler, sensöre ve çözünürlüğe bağlı olarak çok farklı görünebilirler.

Özellikler ve arazi örtüsü veya arazi kullanımı arasındaki ilişki genellikle sadece kaba bir

şekilde modellenir ve belirsizlik, arazi örtü ve kullanım kavramının içinde bile doğal olarak içerilir. Sensör ölçümleri (görüntü pikselleri için ana kaynak) cihazların hassas kalibrasyonundan sonra bile sınırlı radyometrik çözünürlüğe sahiptir. Uzaktan algılamada geometrik çözünürlük (herhangi bir görüntü edinme işleminde) aynı şekilde sınırlıdır. Bu etki bir çözünürlük hücresi kadar sınıf karışmasına yol açar. Şöyle ki; bir çözünürlük hücresi su-kara geçişini kaplıyorsa, ilgili piksel kıyı bölgesini bir miktar suyla ve bir miktar yer örtüsüyle gösterir. Görüntü üretim işlemi sensör ölçümlerini görüntü verisine çevirir. Ek olarak bu veri, arşivleme ve veri transferi gereksinimlerini azaltmak için sıkıştırılmalıdır. Çoğu durumda, bu veri işleme adımları, sonuç görüntü ürününde ek belirsizliklere yol açan, kusur ve tutarsızlıklara sebep olur.

Genellikle arazi örtüsü ve kullanımı için sadece belirsiz fikirler mevcuttur. Yoğun ve seyrek yerleşmiş alanlar arasında veya az çok bitki örtüsüyle kaplı alanlar arasında tam bir sınır yoktur. Her ne zaman sınırlar sayısal terimlerle tanımlanırlarsa, gerçek dünyaya yaklaşım genellikle tatmin edici olmaz. Bu nedenle, sınıflandırma boyunca ve sınıflandırmanın performansının belirlenmesinde sorunlar ortaya çıkar. Uzaktan algılama veri tabanlarından geri alınan bilgi, büyük ölçüde belirsiz bilgiye dayanır. Özellikle önemli kontekst bilgisi tipik olarak sadece belirsiz dil kuralları terimlerinde ifade edilir. Örneğin, eğer ağaçlar “neredeyse tam olarak” yerleşim alanlarıyla çevriliyse park sınıfına dâhil edilirler. Bundan başka, çoğu durumlarda özel bir sınıflandırma işi için beklenen bilgi, o görüntü verisinde hiç içerilmeyebilir ya da yeterli olmayacak düzeydedir. Bu uzaysal veya radyometrik çözünürlükten, sinyal gürültü oranının çok düşük olmasından veya basit olarak, ilgili yerin farklı bilgileri için, sensörün farklı sinyalleri iletmemesinden kaynaklanabilir. Eğer bu belirsizlikler, bilgi çıkarımında dikkate alınmazsa, sınıflandırma robust ve daha sonra kullanılabilir olmaz. Geçişli sınıflayıcılar olarak adlandırılan birkaç yaklaşım mevcuttur. Bunlar, sözü edilen bu belirsizlikleri dikkate alır (Baatz vd. 2004).

3.2.1.3 Segmentasyon İşlemi

Segmentasyon görüntünün birbirinden farklı alt bölümlere ayrılmasıdır (Baatz ve Schäpe 2000). Görüntü segmentasyon işlemleri, yıllar boyunca görüntü analizi alanında ana araştırma odağı olmuş ve çözüm için farklı yaklaşımlar izlenmiştir. Bunlardan yalnızca birkaçı, operasyonel ayarlar altında, robust, uygulanabilir ve nitelik bakımından ikna edici sonuçlar vermiştir ki bir görüntünün istenilen sayıda alanlara segmentasyonunun

astronomik rakamlardaki muhtemel sonuçları olması zor bir problemdir. Çok sayıdaki serbestlik derecesi, verilen gereklilikleri karşılayabilecek bir veya birkaç serbestlik derecesine indirilmelidir. Ayrıca başka bir zorluk da çoğu durumda ilgilenilen alanların heterojen olmasıdır. Heterojenlik durumunda belirsizlikler ortaya çıkar ve gerekli olan, anlaşılması gereken bilgi direkt olarak çıkarılamaz. Bu şekilde problemlerle baş edebilecek, kalite ve performansı ilgilendiren gereklilikleri (veri setinin boyutu ve işletim süresi) ve yeniden üretilebilirliği aynı anda yerine getirebilecek çok az bir yaklaşım mevcuttur.

Görüntü segmentasyonunda arzu edilen, çoğu durumda belirli bir görev için bir görüntüde ilgilenilen, istenilen nesnelerin otomatik olarak çıkarılabilmesinin mümkün olmasıdır. Bunun yanında, bu beklenti, çoğu durumda bu sonuca başarılı bir şekilde ulaşmak için ele alınması gereken çok sayıda semantiği yok sayar ya da problemlerin veya görüntü verisinin sadece indirgenmiş bir türüne uygulanabilen çok özelleştirilmiş algoritmaların geliştirilmesine yol açar. Tabi ki görüntü nesnesi üretimi için birçok çeşit yöntem vardır ve her birinin kendisine özgü avantaj ve dezavantajları mevcuttur; kimisi yarı otomatikken kimisi tam otomatiktir. Genel bir bakışla, görüntü anlamadaki son araştırmalara göre, segmentasyon yöntemleri iki ana gruba ayrılır; bilgi çıkarım yöntemleri (yukarıdan-aşağıya) ve buna karşılık veri çıkarım yöntemleri (aşağıdan-yukarıya). Yukarıdan-aşağıya yaklaşımında, kullanıcı zaten görüntüden ne çıkarmak istediğini bilir, fakat çıkarımı nasıl yapacağını bilmez. İstenilen nesne modeli formülize edilerek, sistem onları çıkarmak için en iyi görüntü işleme metodunu bulmaya çalışır. Formülize edilmiş nesne modeli, nesnelerin anlamlarını üstü kapalı olarak verir.

Aşağıdan-yukarıya yaklaşımında, segmentler bir dizi istatistik yöntem ve parametreyle tüm görüntüyü işlemeye bağlı olarak üretilir. Aslında, aşağıdan-yukarıya yöntemi bir çeşit veri çıkarımı veya sıkıştırma olarak görülebilir. Ama gruplama yöntemlerindeki gibi, başlangıçta üretilen görüntü segmentleri hiçbir anlam ifade etmezler. Daha iyi bir tarifle görüntü nesne primitifleri olarak isimlendirilirler. Üretilen görüntü nesnelerinin ne çeşit gerçek dünya nesnelerini ifade edeceğini belirlemek kullanıcıya bağlıdır. İki yaklaşım arasındaki temel fark; yukarıdan-aşağıya yöntemleri genellikle lokal sonuçlar verir, çünkü hemen model tanımlamasını karşılayan pikselleri işaretler, oysa aşağıdan-yukarıya yöntemleri bütün görüntünün segmentasyonunu gerçekleştirir. Pikselleri, belirli

homojenlik ve heterojenlik kriterini karşılayan uzaysal gruplara birleştirirler. Görüntü nesne primitiflerini temel işlem birimi olarak alan bir nesne tabanlı görüntü analizi yaklaşımında, bir görüntünün tamamının segmentlere ayrılması gerekir. Bu şekildeki genel bir bakışla en genel aşağıdan-yukarıya yaklaşımları düzenlenebilir.

Bazı basit yaklaşımlara örnek olarak, tüm sınır değeri kullanan genel yaklaşımlar verilebilir. Spektral özellik uzayı alt bölümlere ayrılır ve aynı alt bölümlerin pikselleri, görüntü verisi içinde lokal olarak bitişik olduğunda birleştirilir. Bu yöntem bağıl olarak sınırlı kalitede sonuçlara yol açar. Segmentasyon taşması veya eksik kalması (örneğin, çok küçük bölümlere ayırmak veya birbirine ait olmayan alanları birleştirmek) anlamlı sınır değerlerinin iyi kontrol edilmediği durumlarda kolayca meydana gelir. Lokal kontrastlar göz önüne alınmaz ve uygun bir biçimde gösterilmezlerse sonuç alanlar geniş ölçüde boyut olarak farklı olurlar. Alan genişletme algoritmaları pikselleri sınırlı sayıda tekil kaynak noktasından başlayarak birleştirir. Bu algoritmalar temelde verilen kaynak noktalarına bağlıdır ve sıkça bir bölgenin genişlemesi için algoritma içinde kullanılan ölçütlerin tam kontrol altında tutulamamasından dolayı problem çıkarırlar. Sık sık kullanılan eylemsel uygulamalar, farklı çeşitlerdeki doku segmentasyon algoritmalarıdır. Bunlar iki aşamalı tasarıdan oluşurlar:

- Model aşamasında karakteristik özellikler görüntü dokusu içerisinde ve sınırlar ise uzaysal frekanstan çıkarılır. Bunlar Markov Rastgele Alan (MRF) modelleri, birlikte meydana gelme matrisleri, dalga katsayıları, dalga paketleri ve fraktal gösterimlerdir.
- Optimizasyon aşamasında özellikler uygun kalite ölçütüne kadar azaltılarak homojen segmentler halinde sınıflandırılırlar. Buna çoğu sıklıkta, birkaç çeşit gruplama kıymet fonksiyonlarıyla ulaşılır (Baatz vd. 2004).

Doku segmentasyonu her ne kadar çoğaltılmaya öncülük etse de çoğu zaman sadece sınırlı sayıda görüntü verisi, doku tipi ve problem çeşidine uygulanabilir. Dokunun çoğunlukla fark edilebilmesi için çok düzenli olması gerekir. Her seçilen ölçekte sonuçlara ulaşamaz. Segmentasyon aşaması için genel alternatifler bilgi-tabanlı yaklaşımlardır. Çalışma sahasından veya diğer kaynaklardan türetilen bilgileri segmentasyon işleminin içine katmaya çalışırlar. Bu yaklaşımlar çoğunlukla bir global


özellik uzayında, graplama üzerine, piksel tabanlı sınıflandırma yürütürler. Segmentler sınıflandırmadan sonra örtülü olarak üretilirler. Bu işlem basit olarak aynı sınıfa dâhil olan tüm komşu pikseller birleştirilerek yapılır. Böyle olunca, bu yaklaşımda aynı sınıfta, ilgilenilen farklı birim veya nesneleri ayırmak mümkün olmaz. Daha ötesi, sınıflandırmanın işletilmesinde kullanılan bilgi, spektral ve filtrelemeyle türetilmiş bilgiyle sınırlı kalır. Daha güncel bir uygulama, su sınırı segmentasyonudur. İsmi, alanları su toplama havzalarına ayıran algoritmalarda izlenen yoldan alır. Tipik olarak yöntem, öncelikle orijinal veriyi eğim görüntüsüne çevirir. Sonuçta çıkan gri tonlamalı görüntü topoğrafik bir yüzey gibi kabul edilebilir. Eğer bu yüzey minimum değerlerinden itibaren kabartılır ve farklı kaynaklardan gelen su çizgilerinin birleşmesi engellenirse, görüntü su toplama havzaları ve su toplama çizgileri olmak üzere iki farklı bölüme ayrılmış olur. Su toplama havzaları teorik olarak bu görüntünün homojen gri düzeyi alanlarına uymalıdır. Bu yöntem, aslında dışbükey ve bağıl olarak yumuşatılmış nesneleri, hatta hafifçe dokunan nesneleri bağıl olarak homojen görüntü verisi içinde ayırmak için çalışır. Yöntem çalıştığı zaman rahat, hızlı ve güçlüdür. Bununla beraber, uzaktan algılama verisi için, ki belirli bir gürültü içerir ve her zaman kuvvetli kontrast sağlamaz, bu yöntem istenilen sonuçlara ulaşmayabilir.

4. MATERİYAL ve METOT

4.1 Kullanılan Donanım, Veri ve Yazılımlar

4.1.1 Kullanılan Donanım

Çalışmada havadan fotoğraf çekimi için 3 farklı İHA kullanılmıştır. İHA'lar Şekil 4.1'de gösterildiği üzere sınıflandırılabilir.



Şekil 4.1 İHA sınıflandırması.

Çalışmada kullanılan İHA'lar ve kameralar sırasıyla Şekil 4.2-4.5 ve teknik özellikleri çizelge 4.1-4.4'te gösterilmiştir.



Şekil 4.2 Phantom 3 Professional İHA (İnt. Kyn.1).

Çizelge 4.1 Phantom 3 Professional İHA ve kamera Teknik Özellikler (İnt. Kyn.1)


Özellik	Değer
Ağırlık	1280 g
Çapraz Boyut	350 mm
Seyir hızı	2-16 m/s
Maksimum Uçuş Süresi	Yaklaşık 23 dakika
PPK/RTK	Harici isteğe bağlı
Radio link mesafesi	1 km etkili
Kamera modeli	Phantom 3 Professional kamera
Sensör tipi	R-G-B- (12 mp)
Sensör boyutu	1.23-inch
Çözünürlük	4000x3000
Odak uzaklığı	20mm



Şekil 4.3 Sensefly Ebee Plus İHA (İnt. Kyn.2).

Çizelge 4.2 Sensefly Ebee Plus İHA ve S.O.D.A kamera teknik özellikleri (İnt. Kyn.2)


Özellik	Değer
Ağırlık	1100 g
Çapraz Boyut	1100 mm
Seyir hızı	40-110 m/s
Maksimum Uçuş Süresi	Yaklaşık 50 dakika
PPK/RTK	Var
Radio link mesafesi	3 km etkili
Uydu Konumlandırma Sistemleri	Var
Kamera modeli	Sensefly S.O.D.A
Sensör tipi	R-G-B (20 mp)
Sensör boyutu	1-inch
Çözünürlük	5472x3648
Odak uzaklığı	10.6 mm



Şekil 4.4 Sensefly Ebee X İHA ve MicaSense RedEdge-M kamera (İnt. Kyn.3).

Çizelge 4.3 Sensefly Ebee X ve MicaSense RedEdge-M kamera teknik özellikleri (İnt. Kyn.3)

Özellik	Değer
Ağırlık	1400 g
Çapraz Boyut	1160 mm
Seyir hızı	40-110 m/s
Maksimum Uçuş Süresi	Yaklaşık 60 dakika
PPK/RTK	Var
Radio link mesafesi	3 km etkili
Uydu Konumlandırma Sistemleri	Var
Kamera modeli	MicaSense RedEdge-M
Sensör tipi	R-G-B-Re-NIR (16 mp)
5 x tek renkli sensörler çözünürlük	1280 x 960
RGB Çözünürlük	4608x3456
5 x tek renkli sensörler Fokal uzaklık	3.38 mm
RGB Odak uzaklığı	5.40 mm



Şekil 4.5 Parrot Bluegrass İHA ve Parrot Sequoia+ Kamera (İnt. Kyn.4).

Çizelge 4.4 Parrot Bluegrass İHA ve Parrot Sequoia+ Kamera teknik özellikleri (İnt. Kyn.4)

Özellik	Değer
Ağırlık	1810 g
Çapraz Boyut	330 mm
Seyir hızı	2-20 m/s
Maksimum Uçuş Süresi	Yaklaşık 25 dakika
PPK/RTK	Var
Radio link mesafesi	2 km etkili
Uydu Konumlandırma Sistemleri	Var
Kamera modeli	Parrot Sequoia+
Sensör tipi	R-G-Re-NIR (14 mp)
4 x tek renkli sensörler çözünürlük	1280 x 960
RGB Çözünürlük	4608×3456
4 x tek renkli sensörler Fokal uzaklık	3.98 mm
RGB Odak uzaklığı	4.88 mm



Şekil 4.6 Mapir Survey 3 Kamera (İnt. Kyn.5).

Çizelge 4.5 Mapir survey 3 kamera teknik özellikleri (İnt. Kyn.5)

Özellik	Değer
Boyut	59 x 41,5 x 36 mm Uzunluk x Yükseklik x Derinlik
Sensör tipi	R-G-N (12 mp)
Sensör boyutu	6.20 x 4.65 mm
Çözünürlük	4000x3000
Odak uzaklığı	3.37 mm

4.1.2 İHA Görüntü Verisi

Uygulamada, 4 farklı alanda (Afyonkarahisar-Yozgat-İzmir-Bioley/Orjulaz) 5 farklı İHA görüntüsü kullanılmıştır.

Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsünde Phantom Pro 3 İHA ile çekilmiş görüntüler kullanılarak 2 farklı çalışma yapılmıştır. Bu çalışmalardan ilkinde İHA'ya entegreli kamera ile çekilen RGB görüntüler, ikincisinde ise Mapir Survey 3 kamera ile çekilmiş RG-NIR (Red-Green-Near Infrared) görüntüler kullanılmıştır.

İzmir ilinde yapılan çalışmada, Parrot Bluegrass İHA'ya takılmış olan Parrot Sequoia+ kamera ile çekilmiş RGB-Redge-NIR bantlara sahip görüntüler kullanılmıştır.

Yozgat ilinde yapılan çalışmada, Sensefly Ebee Plus İHA ile çekilmiş RGB görüntüler kullanılmıştır.

Sensefly firmasının açık erişim olan veri setlerinin (Bioley/Orjulaz bölgesi) kullanıldığı çalışmada ise Sensefly Ebee X İHA ile çekilmiş RGB-Redge-NIR bantlara sahip görüntüler kullanılmıştır.

4.1.3 Kullanılan Yazılımlar

Bu tez çalışmasında İHA görüntüleri kullanılarak fotogrametrik süreçler (Ortofoto-DSM-DTM vb. üretim) için Pix4D yazılımı; örnek alanlarının belirlenmesi, segmentasyon ve nesne tabanlı sınıflandırma işlemleri için ise eCognition Developer yazılımı kullanılmıştır. Yolları tespit edilen alanların vektör haritalarının düzenlenmesi için Netcad yazılımı kullanılmış olup; son olarak ürün verilerin genelleştirme işlemleri, hata matrislerinin oluşturulması ve doğruluk analizlerinin yapılması için Esri firması tarafından geliştirilen ArcGIS yazılımından yararlanılmıştır.


4.2 Yöntem

Çalışmada veri üretimi için fotogrametrik yöntem, detay çıkarımı için nesne tabanlı sınıflandırma yöntemi kullanılmıştır. Bu kısımda ilk olarak fotogrametrik süreç İHA fotogrametrisi ve Pix4D yazılımı temelinde fotogrametrik ürünlerin üretim yöntemi anlatılacaktır. İkinci olarak ise, 3.3 nolu başlık altında aktarılan nesne tabanlı sınıflandırma işleminin eCognition Developer yazılımındaki süreci aktarılacaktır.

Fotogrametri yönteminin başlangıçtaki amacı, dünyanın topografik yapısını elde etmektir. Bu amaç zaman içinde gelişti ve daha geniş bir yelpazede yeni ve farklı uygulamalar buldu. Günümüzde fotogrametri, canlı ve cansız cisimlerin geometrik ve yapısal özelliklerini kaydetmek, ölçmek ve yorumlamak için kullanılmaktadır (Marangoz 2002).


Haritacılık yönünden fotogrametri, arazinin merkezsel izdüşümü olan resimleri yardımı ile haritalarını elde etme bilimi ve tekniğidir. Genellikle %80 boyuna ve %60 enine bindirmeli olarak çekilmiş fotoğraflardan ilk önce arazinin modeli elde edilir. Daha sonra bu model yardımı ile arazini çizimi yapılır.

Fotogrametrik ölçüm yönteminin temelinde üç aşamadan söz edilebilir (Şekil 4.7). İlki, ölçülmek istenen nesnenin veya arazinin fotoğrafları çekilir ve bunlara ilişkin veri toplanır. İkinci olarak fotoğraflar üzerinde ölçüm yapılmasına olanak sağlayan birtakım fotogrametrik işlemler gerçekleştirilir. Son olarak nesnelerin fotoğraf üzerindeki görüntüleri ölçülür ve çizim yapılabilir. Çizimler özel donanım ve aletlerle gerçekleştirilerek harita, plan veya model biçimine dönüştürülür.



Şekil 4.7 Fotogrametrik süreç.

Fotogrametri temel olarak Şekil 4.8'deki gibi sınıflandırıldığında bilindiği üzere fotogrametrinin ilk uygulamaları yersel fotogrametri alanında yapılmıştır. Fotogrametri'nin ilk uygulamaları yersel fotogrametri ile başlamış olsa da zaman içerisinde harita yapımında geniş olanaklar sağlaması nedeni ile yerini hava fotogrametrisi almıştır. Çünkü geniş alanların haritalarının yapımında hava fotogrametrisi ekonomiden ve hızdan tasarruf sağlamıştır. Diğer birçok alanda olduğu gibi, fotogrametri alanında da hızlı gelişmeler vardır ve zaman aralıklarının kısalmasında yeni yöntemler geliştirilmektedir. Son yıllarda özellikle fotogrametri alanında, sayısal fotogrametri uygulamalarında hızlı değişiklikler yaşanmaktadır. Sayısal fotogrametri sayesinde hem fotoğraf çekimi hem de bu fotoğrafların değerlendirilmesi büyük kolaylık sağlanmıştır.



Şekil 4.8 Fotogrametrinin sınıflandırılması.

Bu kısımda klasik olarak fotogrametrinin sınıflandırmasına ek olarak yeni bir sınıflandırma olan İHA fotogrametrisi de fotogrametrinin sınıflandırmasına dâhil edilmiştir.

Son yıllarda şüphesiz ki, büyük gelişme gösteren ve kendinden söz ettiren taşıyıcı platformlardan biri de İHA'dır. İHA'ların kullanımı ile hem hava hem de yersel fotogrametrinin sağlamış olduğu avantajları bir araya toplanmıştır. İHA, 3B modellemeden, haritacılık, gözetim, izleme ve askeri amaçlar gibi çeşitli amaçlar için kullanılmaktadır (Uysal vd. 2013). Metrik olmayan sayısal kameraların İHA'lara entegrasyonu, fotogrametrik veri toplama ve değerlendirme işlemlerine yeni bir soluk katmıştır.

Çalışma kapsamında İHA fotogrametrisi uygulandığı için diğer fotogrametri türleri aktarılmamıştır.

Terminoloji İHA fotogrametri (Eisenbeiss 2009)'si uzaktan kumandalı çalışan, yarı-bağımsız ya da bağımsız olan, araç içinde oturan bir pilot olmayan, fotogrametrik ölçüm platformunu tanımlar. Platform, fotogrametrik ölçüm sistemleri ile donatılmıştır. Bunun içine, ufak veya orta boy hareketsiz video veya video kamera, termik veya kızıl ötesi kamera sistemleri, hava LİDAR sistemleri dâhildir. Mevcut standart İHA kayıt ve konumu ve uygulanan sensörlerin yönünü bir yerel veya genel koordinat sisteminde

izleme sağlar. Dolayısıyla, İHA fotogrametri yeni fotogrametrik ölçüm aracı olarak anlaşılabilir. HA fotogrametri, hava ve yersel fotogrametrileri birleştirerek, yakın mesafe etki alanında yeni uygulamalara yol açar, fakat aynı zamanda, klasik hava fotogrametrisine, yeni (yakın) gerçek zamanlı uygulamaları ve düşük maliyetli seçenekler ile tanıştırır.


İHA Fotogrametrisi; SfM'nin matematiksel ve istatistiksel modelleri (Structure from Motion, Görüntüden Yapısal Model Oluşturma/Hareketten Yapı) ve geleneksel fotogrametri arasında farklılıklar vardır. İHA fotogrametrisi, 3B nesne rekonstrüksiyonunu kullanır ve bu nedenle doğruluk yerine mevcut tüm verileri kullanarak yerel çözüm ve yerel optimizasyon ile geleneksel fotogrametri ve ışın optimizasyonu modelleri kullanır. Bununla birlikte geleneksel fotogrametri, küresel tutarlılık, model geçerliliği, ölçümlerin doğruluğu, uyumluluk ve temel olarak bütünsel/küresel bir matematiksel model içeren çözümler arar. Bu önemli fark, hava ölçümü, 3B sayısal yüzey modeli oluşturma ve ortofoto oluşturma aracı olarak İHA fotogrametrisinin uygulanmasını ve disiplinlerini sınırlar. İHA fotogrametrisi, geleneksel fotogrametriyi iki gelişim alanıyla değiştirir. Bunlardan ilki İHA fotogrametrisinde kullanılan matematiksel/istatistiksel modeldir. Aynı zamanda bu uygulama noktaları geleneksel fotogrametri ile uyumlu hale getirilmesidir. Diğer ise, bütünsel-küresel bir matematiksel model tasarlama için fiziksel koşulların sağladığı olanakların, geleneksel fotogrametrinin küresel çözümünün temeli olan sensör kamera lens kalitesi ve lens distorsiyonu hakkındaki bilgileri sayesinde İHA sensörleri için de geçerli olmasıdır (Cryderman ve Shufletoski 2015). Öte yandan özel durumlarda, uygulama alanı ve koşullarında İHA fotogrametrisi ile gelişen model ve hesaplama yaklaşımları, geleneksel fotogrametrisinin hesaplama verimliliğini artırmaya katkıda bulunur (Torun 2017).

Sonuç ürün odaklı bir yaklaşım olduğunda fotogrametri ile İHA fotogrametrisinde kullanılan SfM ile arasında fark yoktur, ancak hesaplama yaklaşımları ve süreçleri arasında kesin bir fark vardır. Bu fark fotogrametrinin olgun geometrik, istatistiksel ve matematiksel temellerine dayanmaktadır. İHA fotogrametrisi, bilgisayarlı görmeye, nesne tanımayla, görüntü haritalamaya ve geometrik dönüşüm algoritmalarına ve nokta modelleme modellerine dayanır. Bu fark nedeniyle, planlama, düzenleme ve hesaplama dikkate alınmadığında, belirli koşullar altında iki yaklaşım arasında önemli farklılıklar

ortaya çıkması kaçınılmazdır (Cryderman ve Shufletoski 2015; UAS PIEngineering, 2012; Drayer ve Strecha 2014).

2013 yılında, Almanya, İngiltere, Fransa, Hollanda, İsviçre, Finlandiya, İrlanda ülkelerinin harita ve kadastro kurumlarının katılımıyla EuroSDR çatısı altında gerçekleştirilen İHA, test çalışmasında ve mevzuattan kaynaklanan farklılıklar yayımlanmıştır. Özet olarak, ülkeler; İHA fotogrametrisi tarafından sağlanan olanaklar ve gelişmelerin izlenmeye devam edileceği ve İHA fotogrametrisinin büyük ölçekli çalışmalarda kullanılan hava fotogrametrisinin yerini şu anda alamayacağını ve İHA verilerinin kadastro ve arazi yönetimi gibi konularda yerel olarak güncellemede kullanılabileceği gibi farklı görüşler dile getirilmiştir (Cramer vd.2013).

Gelişen teknoloji ile günümüzde fotogrametrik yazılımlarda büyük gelişme göstermiştir. Pix4D görüntü işleme yazılımı ile otomatik olarak modeller üretilebilmektedir. Elde edilen stereo görüntülerden 3 boyutlu kıymetlendirme yapılabilmektedir. Araziyi ve nesneler detaylı bir şekilde ifade eden Nokta Bulutu, Lazer tarama verileri ile yakın hassasiyettedir. Yazılım havai nirengi dengelemesini, yükseklik verilerinin toplanmasını ve ortofoto üretimini otomatik değerlendirme yöntemleriyle gerçekleştirmektedir. Pix4D yazılımında genel iş akışı Şekil 4.9'da gösterilmiştir.



Şekil 4.9 Pix4d programında süreç takibi.

eCognition yazılımında nesne tabanlı sınıflandırma işlemi; sonuç olarak görüntü bilgisinin nesne tabanlı işlenmesi üzerine kuruludur. Bununla birlikte, segmentasyon ve sınıflandırma için yaklaşımı destekleyici, olanaklarını arttırıcı ve işlem optimizasyonunu

sağlayan özgün yöntemler seçilmiştir. Farklı yöntemler veri giriş çıkışı, vektörleştirme, çalışma, bilgi arayüzleri, doğruluk analizi ve istatistiğiyle bütünü tamamlar.

İlk ve en önemli adım olan segmentasyon, uygulamanın en önemli kısmını oluşturmaktadır. Segmentasyon için orijinal görüntü bilgisinin, istenilen herhangi bir çözünürlükte ve ileriki sınıflandırma işlemlerine uyacak nesne blokları şeklinde çıkarılması gerekir. eCognition bu tip özellikleri karşılayamayan ve nitelik bakımından iyi segmentlerin oluşturulabilmesi için gerekli olan görüntü nesne primitifleri gibi yaklaşımları tam olarak desteklemeyen tüm bilinen segmentasyon yöntemlerini dışarıda bırakmıştır. Bu yüzden eCognition altında “Definiens Imaging” tarafından geliştirilen çoklu segmentasyon adı verilen bir yöntem kullanılmaktadır.

İstenilen ölçekte, görüntü nesne primitiflerini üretme olasılığına bağlı olarak, eCognition birden fazla nesne düzeyi üretmeye ve bu düzeylerin hiyerarşik bir yapıda ilişkilendirilmesine izin verir. Görüntü nesnelerinin bu hiyerarşik yapısı içine entegre edilmiş olarak her nesne onun bitişik nesnesini, alt ve üst nesnelerini tanır. Nesneleri düzeyde ilişkilendirerek, ölçeğe ve gelişmiş doku özelliklerine ulaşmak mümkündür. Nesne hiyerarşisi, farklı ölçeklerde eş zamanlı görüntü bilgisi sunmaya izin verir.

Yazılım altında özel vektörleştirme algoritmaları uygulanabilir ve görüntü nesnelerine vektör bilgisi eklenebilir. Böyle yaparak eCognition altındaki görüntü nesneleri eş zamanlı raster ve vektör sunumu haline gelir. Poligonlar, şekil özelliklerini hesaplamak için dış hat gösteriminde veya sonuçların vektör formatta dışarı verilmesinde kullanılabilir.

Bütün sınıflandırma süreci, bulanık mantık üzerine kuruludur. Bulanık mantık, karışık kural setlerine rağmen sezgisel ve şeffaf düzenlemeye ve işlemeye izin verir. Sınıflandırma bilgi tabanının iskeleti sınıf hiyerarşisidir ki bu sınıflandırma planındaki tüm sınıfları içerir. Her sınıf, bulanık kurallarla tanımlanabilir. Bu tek boyutlu fonksiyonlar üzerine veya çok boyutlu özellik uzayında bile çalışabilen, bir en yakın komşuluk sınıflandırıcısı üzerine de kurulu olabilir. İkisi de kontrollü sınıflandırma metotlarıdır. İlki doğrudan düzenlenebilir ve görüntü içeriği hakkındaki bilgileri formülize etmesine olanak tanır; ikincisi, istenilen sınıf özelliklerine belirlemek için uygun örneklerin seçimine ihtiyaç duyar. Örnekler manuel olarak seçilebilir veya

çalışılan alanların maskeleyesine göre seçilebilir. Farklı sınıflandırıcılar, bulanık mantık kullanılarak bir sınıf tanımlaması altında birleştirilebilir. Bu örneğin “ve” ve “veya” gibi işlemlerle sağlanır. Sınıflandırma sonuçları, semantik kontekst kullanarak farklılaştırılabilir ve geliştirilebilir. Örneğin nesneler fiziksel ve topolojik özelliklerine göre sınıflandırıldıkları gibi, sınıflandırma semantik özellikler kullanılarak hatalarından arındırılabilir (çoğunlukla komşuluk ilişkilerini tanımlayarak veya alt nesnelerin bir araya getirilmesiyle yapılır).

Sınıf hiyerarşisi, sınıfların semantik gruplamasını destekler. Bu farklı özelliklerdeki sınıfların, semantik anlamca üst bir genel sınıfa atanmasında kullanılabilir. Bu bağlamda, üst sınıf, kendi açık sınıf tanımlamalarına ihtiyaç duymaz. Kentsel yeşil alan ve kentsel geçirimsiz, örneğin kentsel sınıfı altında gruplandırılabilir. Bu durumun kendine özgü bir avantajı, üst sınıfla olan kontekst ilişkileri tarif etmektedir: kentsel sınıfı içinde olmak hem kentsel geçirimsizi hem de kentsel yeşili gösterir. Bunlara ek olarak, sınıf hiyerarşisi, kalıtsal olarak sınıf tanımlamalarının, alt sınıflara geçmesini sağlar. Örneğin yeşil alan gibi bir sınıf, sınıf tanımlamalarını, kentsel yeşil veya kırsal yeşil gibi alt sınıflara kalıtsal olarak geçirerek değiştirilebilir. Bu bilgi tabanının şeklini oluşturur yani, bir sınıfın tanımlamasının detay seviyesi arttıkça, hiyerarşi kolları derinleşir.

Bu imkânlarla, sınıf hiyerarşisi şaşırtıcı semantik zenginlikte, iyi kurulmuş bir bilgi tabanının, etkin bir şekilde oluşturulmasını sağlar. Bulanık mantıkla birlikte bu nesne tabanlı görüntü analizi yaklaşımına çok fazla güç katar. Burada dikkat edilmesi gereken en önemli husus; sınıf hiyerarşisinin farklı bir şey olduğu ve görüntü nesnesi hiyerarşisinden bağımsızlığıdır. Sonunda, nesnelerin şekilleri, sınıflandırmayla ve bilgi tabanlı segmentasyonla geliştirilebilir. Genellikle bu yeni özellikli ve semantik ilişkili, sırasıyla, yeni üretilen özelliklerine göre sınıflandırılan yeni nesnelere yol açar (Baatz vd. 2004; Marangoz 2009).

4.3 Doğruluk Analizi/Karşılaştırma Verisi – Vektör Harita

Sınıflandırma tamamlandıktan sonra mevcut sınıfların yer gerçeği ile ne kadar uyumlu olduğunu belirlemek için tüm çalışma alanında doğruluk analizi yapılmıştır. Doğruluk analizi, sınıflandırmanın doğruluğunu ve güvenilirliğini ölçmek için gerçekleştirilen son işlem adımıdır. Sınıflandırma sonuçlarının doğruluk analizi için ilk olarak eCognition

yazılımın sağladığı “Error matrix based on TTA mask” yaklaşımı kullanılmıştır. Seçilen test alanlarının referans değerleri ile sınıflandırma sonucu karşılaştırılarak hata matrisi üretilmiş ve sınıflandırma kalitesi test edilmiştir.

Sınıflandırma sonuçlarının validasyonu için sınıflandırma doğruluğu elde edilen sonuçları anlamak ve sonuçların karar verici mekanizmalarca kullanılabilmesi için doğru tahminler gereklidir. En yaygın doğruluk tahmin parametreleri genel doğruluk, üretici doğruluğu, kullanıcı doğruluğu ve Kappa katsayısıdır (Lu vd.2004). Genel doğruluk ve Kappa katsayıları bu çalışmada doğrulukların değerlendirilmesi amacıyla kullanılmıştır.

Genel doğruluk, doğru olarak sınıflandırılan toplam piksel veya görüntü nesnesi sayısının referans verilerindeki toplam öge sayısına bölünmesiyle hesaplanır. Burada genel doğruluk,

$$Genel\ doğruluk = \frac{\sum_{k=1}^n N_{k,k}}{\sum_{j=1}^n (\sum_{i=1}^n N_{i,j})} \quad (4.1)$$

şeklinde olur.

Her bir kategorinin doğruluğu, bu kategoride doğru sınıflandırılmış nesnelerin sayısının karşılık gelen satır veya sütundaki eleman sayısından herhangi birine bölünmesiyle hesaplanır.

Üretici doğruluğu, her kategoride doğru sınıflandırılmış piksel veya nesne sayısının, o kategori için seçilen toplam gerçek örnekleme türü sayısına (sütun toplamı) bölünmesiyle hesaplanır.

$$PAN_i = \frac{N_{i,i}}{\sum_{j=1}^n N_{i,j}} \quad (4.2)$$

Üretici doğruluğu denklem 4.2’de gösteriliği gibi hesaplanır. Burada, PAN_i , (PAN= producer accuracy for normal class) i . kategorinin üretici doğruluğu, n sınıflandırma kategori sayısını oluşturmaktadır. Üretici doğruluğu, görüntüdeki gerçek örtü tipinin ilgili sınıfa dâhil edilme başarısını gösterir.

Kullanıcı doğruluğu, her kategoride doğru olarak sınıflandırılan piksel veya nesne sayısının, o kategoride sınıflandırılan toplam piksel veya nesnelerin (toplam satır)

sayısına bölünmesiyle elde edilir. Bu doğruluk kriteri, ekleme hatasının bir ölçüsüdür ve belirli bir kategoride sınıflandırılan piksel veya nesnenin, gerçek dünya toprak örtüsü tipindeki kategoriye temsil etme olasılığını ifade eder. Kullanıcı doğruluğu,

$$UAN_j = \frac{N_{j,j}}{\sum_{i=1}^n N_{j,i}} \quad (4.3)$$

ile hesaplanır. Burada, UAN_j , j . (UAN = users accuracy for normal class) kategorinin kullanıcı doğruluğudur.

Bu prosedürlerin sadece bu alanlardan türetilen istatistiklerin bu alanları kategorize etmek için ne kadar iyi kullanılabileceğini ifade ettiği bilinmelidir. Sonuçlar iyi ise, eğitim alanlarının homojenliğinden, spektral ayrılabilirliklerinden ve uygulanmakta olan sınıflandırma stratejisinden daha fazlası anlamına gelmez.

Doğruluk analizi, sınıflandırma sonucunda elde edilen verilerin referans olarak kabul edilmiş olan veriler ile istatistiksel olarak karşılaştırılmasını esas alan bir doğruluk kontrol etme yöntemidir. Yapılan bu istatistiksel analizler sonucunda elde edilen hata matrisi ile sınıflandırma sonucunun sağlıklı olup olmadığı anlaşılmaktadır. Hata matrisi, 0 ile 1 arasında değişiklik gösteren kappa katsayısı ile istatistiksel olarak analiz edilir (Çölkesen vd.2007).

k değeri kappa katsayısını göstermek üzere,

$$k = \frac{P_0 - P_h}{1 - P_h} \quad (4.4)$$

ile hesaplanır.

P_0 değeri hata matrisinin köşegenlerindeki elemanların toplamının, her satır veya sütundaki elemanlarının toplamına oranlanması ile elde edilir.

$$P_h = \sum P_a(i)P(i) \quad (4.5)$$

P_a değeri, ayrı ayrı her bir sütunun toplamının, tüm sütunların toplamına bölünmesi ile bulunmaktadır.

P değeri ise, ayrı ayrı her bir satırın toplamlarının, tüm satırların toplamına bölünmesi ile bulunmaktadır (Musaoğlu 1999).

eCognition Developer yazılımında doğruluk analizi yapılabilmesi için 4 farklı işlem bulunmaktadır;

Classification Stability - Best Classification Result - Error Matrix based on TTA Mask - Error Matrix based on Samples

Hata matrisleriyle yapılacak doğruluk analizi için iki yöntem vardır. İlkinde, “TTA maskesine dayalı hata matrisi (Error matrix based on TTA mask)” yöntemi; Sınıflandırma kalitesi, seçilen test alanlarının referans piksel değerleri ile sınıflandırma sonucu karşılaştırılarak test edilir. Bu aşamada kullanılacak örnek test alanları, her sınıf için ayrı ayrı mevcut nesne katmanından toplanır ve ilgili sınıfa atanır.

"TTA örneklerine dayalı hata matrisi (Error matrix based on TTA samples)" yöntemi test alanlarını manuel olarak toplar, temelde "TTA maskesine dayalı hata matrisi" yöntemiyle aynıdır.

Bu çalışma kapsamında, Definiens Developer yazılımının sahip olduğu doğruluk analizi işlemlerinden en güvenilir olan ve piksel tabanlı yaklaşıma benzer özellikler gösteren “Error Matrix Based on TTA Mask” seçeneği ile doğruluk analizi yapmak için kullanılmıştır.

$$K = \frac{N \sum_{i=1}^r X_{ii} - \sum_{i=1}^r (X_{it} - X_{ti})}{N^2 - \sum_{i=1}^r (X_{it} - X_{ti})} \quad (4.6)$$

r: Hata matrisindeki satırların sayısı

xii: Satır i ve sütun i’deki gözlemlerin sayısı (ana köşegen üzerinde)

xti: Satır i’deki toplam gözlem

xit: Sütun i’deki toplam gözlem

N: Matriste içerilen toplam gözlem sayısı

eCognition developer yazılımında ilk önce doğruluk analizi yapılacak alana ait örnek segmentler tanımlanır. Örneklem sayısı belirlenerek her sınıfa ait örnek segmentler gösterilir. Doğruluk analizine daha anlamlı ve daha güvenilir sonuçlar vermek için,

doğruluk analizi sırasında seçilecek örneklerin küçük segmentlerden seçilmesi önemlidir. Nesne boyutu azaldıkça, nesnedeki homojenlik paralel olarak artacaktır. Büyük nesneleri örnek olarak seçerken, bu nesneler içindeki farklı spektral özelliklerin ve sınıfların heterojen yapısı sınıflandırma doğruluğunu etkiler. Örnek seçim alanlarının boyutları 180 piksel olarak seçildi.

Örnekleme alınmasında örneklemin alındığı evreni temsil etmesi önemlidir. Bu durumda ne kadar, hangi büyüklükteki bir örneklemin evreni temsil edebileceği sorunu ortaya çıkmaktadır. Alınan örneklemin evreni temsil yeterliği bulunmadığında örnekleme hatası olur. Örneklem büyüklüğünü saptamak için evren büyüklüğünün on binin üzerinde olmasından dolayı bu çalışmada örneklem belirlemek için denklem 4.7 kullanılmıştır.

$$n = \frac{Nt^2pq}{d^2(N-1)+t^2pq} \quad (4.7)$$

N: Hedef kitledeki birey sayısı (ana kütle sayısı)

n: Örnekleme alınacak birey sayısı

p: İncelenen olayın görülüş sıklığı (gerçekleşme olasılığı) (0,5)

q: İncelenen olayın görülmeysi sıklığı (gerçekleşmeme olasılığı) (1-p)

t: Belirli bir anlamlılık düzeyinde, t tablosuna göre bulunan teorik değeri (1,96)

d: Olayın görülüş sıklığına göre kabul edilen $\pm$ örnekleme hatası ($\pm 0,05$) (Karatay 2004)

eCognition Developer yazılımında Error matrix based on samples ile doğruluk analizleri yapılmıştır. Sınıflandırma doğruluğunun analizinde, belirlenen çalışma alanında her bir İHA görüntüsüne ait, her sınıf için farklı sayıda referans segmentleri tespit edilmiştir. Seçilen referans segmentleri ile sınıf atamalarındaki segmentler arasındaki ilişki incelenmiştir. Ayrıca çalışma alanlarına ait vektör haritalar ile tespit edilen yolların vektör çizimleri karşılaştırılmıştır. Vektör çizimler için Netcad, vektör haritaları raster dönüşüm ve karşılaştırma için MapInfo yazılımı kullanılmıştır. Karşılaştırmada rastgele noktalar atılmış ve noktaların konumları dikkate alınmıştır. Bunun için örneklem büyüklüğü incelenmiş ve gerekli olan örneklem sayısı kadar rastgele nokta atılmıştır.

Rastgele atılan aynı noktalar, tespit edilen yolların olduğu harita üzerine de atılmıştır.

İlk olarak bu işlem içinde örneklem tespit edilmiştir. Örneklem sayısı belirlendikten sonra

bu sayı kadar rastgele nokta atılmıştır. Atılan bu noktaların, referans verisindeki konumlarının tespit edilen yolların oluşturduğu vektör haritadaki durumu incelenmiştir. Bunun için;

Gerçek pozitif (TP): yol noktaları doğru sınıfa (Evet)

Gerçek negatif (TN): yol olmayan noktalar yol olmayan sınıfa (Hayır)

Yanlış pozitif (FP): yol olmayan noktalar yol sınıfa (Evet)

Yanlış negatif (FN): yol olan noktalar yol olmayan sınıfa (Hayır)

$$Doğruluk = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (4.8)$$

$$Hassasiyet = \frac{(TP)}{(TP+FP)} \quad (4.9)$$

$$Duyarlılık = \frac{(TP)}{(TP+FN)} \quad (4.10)$$

$$F_1Puanı = 2 * \frac{(Hassasiyet * Duyarlılık)}{(Hassasiyet + Duyarlılık)} \quad (4.11)$$

$$Özgünlük = \frac{(TN)}{(TN+FP)} \quad (4.12)$$

5. UYGULAMA


Tez çalışmasında, 4 farklı alanda yapılan 5 farklı uygulamanın iş akış şeması Şekil 5.1’de verilmiştir.



Şekil 5.1 İş akış şeması.


Çalışmada veri temini, İHA ile havadan görüntü alımı ile gerçekleştirilmiştir. 1-2-3 ve 4. Çalışmalarda arazide Cors/RTK cihazı ile ölçülen YKN’ler kullanılarak noktalar gerçek konumuna getirilmiştir (Mekansal referanslama yapılmıştır). Fotogrametrik değerlendirme (Ortofoto vb. üretim) işlemleri Pix4D yazılımında gerçekleştirilmiştir. Nesne tabanlı sınıflandırma işlemi Ecgonition Developer yazılımında, vektör haritaların düzenlenmesi Netcad yazılımında ve doğruluk analizi MapInfo yazılımında yapılmıştır.

5.1 Çalışma 1 (Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer kampüsü-RGB Görüntüler)



Şekil 5.2 Afyon ilinin konumu ve coğrafi koordinatları.

İlk çalışma alanı olarak Afyonkarahisar ilinde (Şekil 5.2) bulunan Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsü seçilmiştir (Şekil 5.3). Bu alanda iki farklı çalışma yapılmıştır.



Şekil 5.3 Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsü (Sol: ortofoto – Sağ: DSM).

5.1.1 Veri Temini

Çalışma alanı yaklaşık 252 hektarlık bir alandan oluşmaktadır. Çalışma alanına ait hava görüntüleri Phantom Pro 3 İHA (Şekil 4.2) ile 120 metre yükseklikten nadir konumdan ve bindirmeli olarak çekilmiştir. Toplam 808 fotoğraf çekilmiş olup tamamı kullanılmıştır. Araziye 6 adet yer kontrol noktası (YKN) tesis edilmiş olup yer kontrol noktalarının ölçümü CORS/RTK ile gerçekleştirilmiştir.

5.1.2 Fotogrametrik Süreç

İHA ile çekilen görüntüler, Pix4D yazılımı aracılığıyla fotogrametrik olarak dengelemesi yapılmıştır. Dengeleme sonunda araziden ölçümü yapılan YKN kullanılarak arazi koordinatlarına dönüştürülmüştür. Daha sonra çalışma alanının ortofotosu üretilmiştir. Üretilen ortofotoların yer örneklem aralığı (GSD) 3,7 cm çözünürlüğe sahiptir. Çalışma alanına ait ortofoto Şekil 5.3’de gösterilmiştir. Pix4D yazılımında fotogrametrik değerlendirme yapıldıktan sonra Omega, Phi, Kappa değerleri sırasıyla 0.533-0.854-6.839 elde edilmiştir.

4.1.3 Nesne Tabanlı Sınıflandırma

Nesne tabanlı sınıflandırmada en önemli ve ilk aşama segmentasyon aşamasıdır. Segmentasyon, benzer spektral özelliklere sahip piksellerin gruplandırılması ve görüntü nesnelerinin oluşturulması işlemidir. Segmentasyonun amacı; görüntünün birbirinden farklı alt bölümlere ayrılması ve görüntüden anlamlı nesneler yaratılmasıdır (Baatz ve Schape, 2000). Ayrıca, çoğu durumda belirli bir görev için bir görüntüde ilgilenilen, istenilen nesnelerin otomatik olarak çıkarılmasının mümkün olması da segmentasyonun amaçları arasındadır. Segmentasyon işlemi, yukarıdan-aşağıya (topdown) ve aşağıdan-yukarıya (bottom-up) olmak üzere iki farklı yöntem olarak işlemektedir (Definiens 2012).


Yukarıdan aşağıya yönteminin temelinde bütünün en küçük parçalara ayrılması işlemi vardır. 3 farklı yukarıdan aşağıya segmentasyon metodu bulunmaktadır. Bunlar; satranç tahtası segmentasyon (chessboard segmentation), dörtlü ağaç tabanlı segmentasyon (quadtree-based segmentation) ve kontrast bölümlemesi segmentasyon (contrast split segmentation) algoritmalarıdır. Segmentasyon işleminin ikinci stratejisi aşağıdan yukarıya bölümleridir. Bu yaklaşımda, küçük parçalar belirli bazı kriterler göz önüne alınarak büyük parçalar olarak elde edilmektedir. Aşağıdan yukarıya strateji için kullanılan en önemli yöntem “Çoklu Çözünürlüklü Segmentasyon (Multiresolution Segmentation)” yöntemidir (Benz vd. 2004).

Satranç tahtası segmentasyonu: Görüntüyü eşit kareler şeklinde görüntü nesnelerine ya da piksel gruplarına ayıran segmentasyon işlemidir. Görüntünün sol üst köşesinde oluşturulan kare hiza alınarak görüntü karelere bölünür (şekil 5.4).




Şekil 5.4 Satranç tahtası segmentasyonu (Object Size: 50).

Dörtlü ağaç segmentasyonu: Görüntüyü farklı kareler şeklinde görüntü nesnelere ya da piksel gruplarına ayıran segmentasyon işlemidir. Satranç tahtası segmentasyonundan farklı görüntü kare ve bu karenin katlarına bölünür (Şekil 5.5).




Şekil 5.5 Dörtlü ağaç segmentasyonu (Scale parameter: 50).

Kontrast bölme segmentasyonu: Görüntüyü karanlık ve parlak alanlara ayırarak segmentasyon işlemi gerçekleştirir. Öncelikle görüntü satranç tahtası segmentasyonu ile segmentlere ayrılır daha sonra görüntüdeki minimum ve maksimum kontrast değerleri kareler ve her piksel için hesaplanır ve piksel bulunduğu kareye ölçek parametresi ile ya dahil edilir ya da kareden çıkartılır (Şekil 5.6).



Şekil 5.6 Kontrast bölme segmentasyonu (Chessboard Tile Size: 100).

Çoklu çözünürlüklü segmentasyonu: Belirli bir çözünürlük için görüntü nesnelerinin ortalama heterojenliği içinde küçük parçalara ayırma işlemidir (Şekil 5.7). Bu piksel seviyesinde ya da görüntü alt nesnelere uygulanabilir.



Şekil 5.7 Üç ayrı katmanda oluşturulan görüntü segmentasyonu sonrasındaki görüntü nesnelerinin hiyerarşik ağ yapısı (Karakış vd. 2005).

Görüntü nesnelerinin hiyerarşik ağ yapısı, aşağıda açıklanan daha yeni teknikler için imkân sağlamaktadır:

- Farklı ölçeklerdeki yapılar eş zamanlı sunulabilir ve böylece birbirleriyle olan ilişkilerine göre sınıflandırılabilirler.
- Farklı hiyerarşik seviyeler, farklı verilere dayalı olarak segmentlere ayrılabilir; bir üst seviye örneğin tematik arazi kayıt bilgilerine göre kurulabilirken, alt seviye uzaktan algılama verisi kullanılarak segmentlere ayrılabilir. Bir üst seviyeyi sınıflandırarak, her bir arazi kayıt nesnesi, sınıflandırılmış alt nesnelerinin bir araya gelmesi ile analiz edilebilir. Bu teknik mantığıyla, değişik veri tipleri birbirleriyle olan ilişkileriyle analiz edilebilirler.
- Görüntü nesnelerinin şekilleri alt nesnelerin yeniden gruplandırılmasına bağlı olarak düzeltiler. Segmentasyon işleminde ölçek parametresi görüntü nesneleri için verilen maksimum heterojenlik sınırını geçmemesini sağlar. Burada ölçek parametresi bir eşik değerdir (Burnett ve Blaschke 2003).

Böyle bir durumda segmentlere ayrılan seviyelerin ardışıklığı önemli bir rol oynar. Hangi seviyenin önce yapıldığı bile fark yaratır. Örneğin, önce kadastral seviyeyi kurup sonra alt nesneleri oluşturmak anlam ifade eder. Yine, aynı üst nesnenin alt nesneleri olmayan, bitişik nesneler birleştirilemez. Güçlü bir teknik, alt nesnelere dayalı görüntü analizi tekniğidir. Aşağıda sıralanan analizler bu noktada kullanılabilecek, basit ama uygulamayı şekillendirecek özellikleri göstermektedir:

- Alt nesnelere dayalı doku analizi, bir görüntü nesnesinin tüm alt nesnelerin sınıflandırma nitelikleri.
- Alt nesnelere dayalı çizgi analizi.
- Sınıfa dayalı özellikler: sınıflandırılmış alt nesnelerle olan ilişkiler.

Görüntü nesnelerinin başka bir hiyerarşik ağ yapısı uygulaması, görüntü nesnelerini, ayrı ayrı üst nesnelere göre sınıflandırmaktır (Baatz vd. 2004).

eCognition tarafından sağlanan tüm segmentasyon işlemleri, bu hiyerarşik ağ yapısı içinde keyfi seçilmiş bir seviyede gerçekleştirilir. Piksellerin seviyesi ve tüm görüntünün seviyesi tanımlamayla varken her bir yeni seviyenin segmentasyonu, bir alt ve bir üst seviyelerin arasında bir iç yapılaşmadır. Tüm nesnelerin uzaysal şekilleri üzerindeki belirli hiyerarşiyi garanti altına almak için segmentasyon işlemi iki kural izler:


- Nesne sınırları, bir sonraki alt seviyenin nesne sınırlarını takip etmelidir.
- Segmentasyon, bir sonraki üst seviyedeki nesnelerin sınırlarıyla kısıtlıdır.

Çoklu çözünürlüklü segmentasyon algoritmasında parametreler kullanıcı tarafından belirlenir. Bu parametreler ölçek, renk ve şekil parametreleridir. Parametreler mümkün mertebe gerçeğe en yakın değerde girilmelidir. Girilen 3 parametre içinde en önemlisi ölçek parametresidir. Renk ve şekil parametreleri birbirini 1'e tamamlar. Çoklu çözünürlüklü segmentasyon, nesne yönelimli sınıflandırmanın temelidir. Ölçek, şekil ve renk parametrelerini ayarlayarak çokgen nesneler üretmek için görüntüyü herhangi bir ölçekle bölümlere ayırabiliriz.

Ölçek parametresi: Ölçek Parametresi segmentler için izin verilen maksimum heterojenliği belirleyen soyut bir terimdir. Spektral homojenliği düzenlerken bütünlük parametresi bütün kenarları esas alıp bütünlük ve yumuşaklık dengelemesini yaparak nesnenin şeklini belirlemektedir (Bilgilioğlu 2015).


Renk parametresi: Şekil homojenliği kriterine karşı gelen görüntü katmanının, spektral yansıma değeri tarafından belirlenen ortalama homojenliğe hangi oranda denk geldiğini belirler (Bilgilioğlu, 2015).

Şekil parametresi: Şekil parametresi yumuşaklık ve bütünlük parametrelerinin birleşimidir. Yumuşaklık parametresi görüntü nesnelerinin sınırlarının yumuşatılması için uygun kriteri belirlerken bütünlük parametresi görüntü nesnelerinin bütünlüğü için uygun kriteri belirler (Bilgilioğlu 2015). Çoklu çözünürlüklü segmentasyon için ölçek parametresinin genel diyagramı Şekil 5.8’de gösterilmiştir.



Şekil 5.8 Çoklu çözünürlüklü segmentasyon için ölçek parametresinin genel diyagramı (Altunkaya 2011).

Ölçek parametresi, segmentasyon işlemi aşamasında önemli bir yer edinmektedir. Şekil 5.9’da görüleceği gibi ölçek parametresini değiştirerek görüntü nesnelerinin boyutunu da değiştirebiliriz.



Şekil 5.9 Farklı ölçekteki çoklu çözünürlüklü segmentasyon (Scale parameter = Sol: 60 – Sağ: 100 / Shape = 0.4 / Compactness = 0.6).

Heterojenlik kriteri (f) belirli bir eşik değerinin altında olmalıdır. Ağırlık parametreleri olan W_{color} ve W_{shape} heterojenliği belirler.

$$f = W_{color} \cdot \Delta h_{color} + W_{shape} \cdot \Delta h_{shape} \quad (5.1)$$

$$W_{color} \in [0,1], W_{shape} + W_{color} = 1 \quad (5.2)$$

$$\Delta h_{color} = \sum_c w_c \cdot (n_{merge} \cdot \sigma_{c,merge} - (n_{obj-1} \cdot \sigma_{c,obj-1} + n_{obj-2} \cdot \sigma_{c,obj-2})) \quad (5.3)$$

Bu denklemlerde:

w_c : c bandındaki ağırlığı

n_{merge} : birleştirilmiş nesne içindeki toplam piksel sayısı

n_{obj-1} : birinci nesne içindeki toplam piksel sayısı

n_{obj-2} : ikinci nesne içindeki toplam piksel sayısı

σ_c : c banttaki standart sapma

$obj - 1, obj - 2$: birleşimden önceki nesneler olarak tanımlanır.

Şekil parametresindeki (shape) değişim (Δh_{shape}), yumuşaklık (smoothness) ve bütünlük (compactness) olarak iki farklı parametre ile belirlenir. Burada yer alan w_{smooth} ve w_{compt} yumuşaklık ve bütünlüğe ilişkin ağırlık değerleridir ve 0 ile 1 arasında bir değer ile tanımlanır. Δh_{smooth} ve Δh_{compt} ise bu değerlerin farklarıdır (Bilgilioğlu, 2015). Bu parametreler verilen Denklem 4.4, 4.5 ve 4.6 ile hesaplanır.

$$\Delta h_{shape} = W_{compt} \cdot \Delta h_{compt} + W_{smooth} \cdot \Delta h_{smooth} \quad (5.4)$$

$$\Delta h_{smooth} = n_{merge} \cdot \frac{l_{merge}}{b_{merge}} - (n_{obj-1} \cdot \frac{l_{obj-1}}{b_{obj-1}} + n_{obj-2} \cdot \frac{l_{obj-2}}{b_{obj-2}}) \quad (5.5)$$

$$\Delta h_{compt} = n_{merge} \cdot \frac{l_{merge}}{\sqrt{n_{merge}}} - (n_{obj-1} \cdot \frac{l_{obj-1}}{\sqrt{n_{obj-1}}} + n_{obj-2} \cdot \frac{l_{obj-2}}{\sqrt{n_{obj-2}}}) \quad (5.6)$$

Yukarıdaki eşitliklerde,


l: nesnenin çevre uzunluğu,

b: nesne hattını çevreleyen uzunluk olarak tanımlanır. Görüntü segmentasyonunda iyi bir sonuç elde edilebilmesi için denklemleri verilen 5 parametreye (w_c , w_{color} , w_{shape} , w_{smooth} , w_{compt}) ihtiyaç vardır. Ölçek parametresi optimizasyon işlemini durdurmak için gerekli olan parametredir. Heterojenlik farkı (f) iki komşu nesne birleştirilmeden önce hesaplanır. Artış

miktarı ölçek parametresi tarafından belirlenen t ($t = \Psi$ (ölçek parametresi)) eşik değerini geçtiğinde nesneleri birleştirme işlemi durdurulur ve segmentasyon işlemi biter. Daha büyük ölçek parametresi belirlenmesi daha çok nesnenin birleştirileceği ve böylelikle daha büyük nesnelerin oluşacağı anlamına gelir (Benz vd. 2004).

Segmentasyon işleminde ölçek parametresi, şekil parametresi ve bütünlük parametresi olmak üzere üç adet parametre esastır. Bütünlük parametresinin oluşturulan segmentler üzerinde kayda değer bir etkisi görülmemektedir. (Kavzoğlu 2014). Parametreler mümkün mertebe gerçeğe en yakın değerde girilmelidir. Girilen 3 parametre içinde en önemlisi ölçek parametresidir. Bütünlük ve şekil parametreleri birbirini 1'e tamamlar (Çömert vd. 2012). Bundan dolayı ilk olarak bütünlük ve renk parametresi 0.5 seçilerek ölçek parametreleri üzerinde denemeler yapılmıştır.

Öncelikle ortofoto görüntüsü için bütünlük parametresi ve şekil parametresi 0.5, ölçek parametresi ise 30 ile 150 arasında değerler ve bunlara ek 200 değeri verilerek en uygun ölçek parametresi bulunmaya çalışılmıştır. Ortofoto görüntüsünde ölçek parametresi için yapılan denemeler Şekil 5.10'da gösterilmiştir.




Şekil 5.10 Ortofoto görüntüsü için ölçek parametresi araştırması (Bütünlük-şekil:0.5 seçilmiştir).

Yapılan bir segmentasyon işleminin optimum düzeyde olduğunu değerlendiren en iyi ve tecrübeli kaynak şüphesiz insan gözüdür. Bu sebeple segmentasyon sonucu (nicel olarak çok iyi hesaplanmış olsa bile) insan gözünü yeterince memnun etmediği sürece tam olarak anlamlı sayılmaz. Burada oluşan görüntü segmentlerinin görüntü nesneleri ile benzer şekilde ve boyutta olması önemlidir. Ancak burada en az sınır yumuşatması ile görüntü nesnelerinin üretilmesi için karışık ve dokulaşmış verideki spektral homojenliğin ortaya

ıkarılması olduka zordur (Karakıs vd. 2005). Bütünlük ve ekil parametresi sabit tutularak belirlenen ölek parametreleri (20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 200) teker teker denenmiřtir. Her detayın kendisine özü bir ölek parametresi vardır. Bundan dolayı tespit edilmesin istenilen nesneye öre segmentlerin seilmesi önemlidir. Örneğın bina detayının ıkarımı için belirlenen ideal ölek parametreler daha küçük iken yol detayının ıkarımı için belirlenen ideal ölek parametresinin daha büyük olduėu gözlemlenmiřtir. Bu sebepten dolayı ekil ve bütünlük parametreleri sabit tutularak yapılan ölek arařtırmasında 120 deėeri uygun görölmüřtür. Uygun görölen ölek parametresinden daha büyük deėerlerde, yol üzerindeki araba gibi nesnelerin yol ve zemin ile karıřtıėı gözlemlenmiřtir. Daha küçük ölek parametrelerinde ise küçük segmentlerin oluřmasından dolayı veri kalabalıėı ortaya ıkmaktadır.

Ölek parametresi belirlendikten sonra ölek sabit tutularak ekil ve bütünlük parametlerin arařtırılması yapılmıř ve ekil 5.11’de gösterilmiřtir.



ekil 5.11 Ortofoto görüntüsü için ekil ve bütünlük parametresi arařtırması (Ş:ekil – B:bütünlük – Ölek:120).

Yapılan denemelerde ölek parametresi artırıldıėında nesnelerin alanlarının da arttıėı görölmüřtür. ekil parametresi artırıldıėında ise nesneler büyümetedir fakat bu büyüme


ile nesnelerdeki homojenliğin azaldığı ve bir nesnenin içerisine birden fazla sınıfın dâhil olduğu görülmüştür ki buda şekil parametresinin belirlenmesinde, nesnelerin spektral özelliklerinden çok nesnelerin boyut ve şekil özelliklerinden yararlanıldığını göstermektedir. Şekil parametresi 0.9 olarak alınan segmentasyon işleminde oluşan segmentlerde bina, yeşil alan, yol, taşıt ve toprak gibi sınıfların farklı kombinasyonlarda tek bir nesneye dâhil olduğu görülmüştür (Bilgilioğlu 2015).

Sınıflandırmaya geçmeden önce görüntünün tümü ekran üzerinde ayrıntılı incelenerek segmentlerin nesnelerle olan uyumu ve bütünlüğü incelenmiştir. Şekil 5.12’de örnek incelenen bir alan gösterilmiştir.



Şekil 5.12 Sınıfların birbiri ile karışması (ölçek: 80 – şekil: 0.8 – Bütünlük: 0.2 seçilmiştir).

Bu aşamada çeşitli sebeplerle bütünlüğü bozulmuş veya başka nesneye ait segmente karışmış olan bazı nesneler Şekil 5.13’te sögterilen yazılımın elle nesne ayırma ve nesne birleştirme özellikleri kullanılarak düzeltilmiştir.



Şekil 5.13 eCognition yazılımında elle müdahale.

Manuel müdahale öncesi Şekil 5.12’de, düzeltme sonrası Şekil 5.14’te gösterilmiştir.



Şekil 5.14 eCognition yazılımında segmentlerin elle düzeltilmesi.


Yapılan bu düzeltmelerin amacı yanlış segmente dolayısı ile yanlış sınıfa dâhil olacak olan nesneleri, işlemin otomatikliğine zarar vermeyecek şekilde ayırarak veya birleştirerek doğru sınıfa dâhil edilmesini sağlamaktır.

Nesne tabanlı sınıflandırma işleminde segmentler oluşturulduktan sonra, çeşitli bant kombinasyonları oluşturulur ve karşılık gelen aralıktaki nesneler gri renk tonunda elde edilen aralıktan istenen detaylar çıkartılır. Bu işlemin amacı, kullanılan bant kombinasyonlarının özelliklerini ve görüntüdeki ayrıntıları ortaya koymaktır. Bunun için literatürde birçok grup kombinasyonu vardır. Çalışma 1 kapsamında kullanılan görüntü bize sadece RGB veri verdiği için bu bant kombinasyonlarına göre sınıflandırma işlemi gerçekleştirilmiştir. Literatürde bulunan ve en çok kullanılan bazı indeksler çizelge 5.1’de verilmiştir.

Çizelge 5.1 Literatürdeki temel RGB bant indeksleri


İsim	Kısaltma	Formül	Referans
Ortak Bantlar Oranı	OBO	$\frac{(R + G + B)}{3}$	Çömert vd. 2017
Kırmızı Yeşil Bant Farkı	K-Y	$R - G$	Çömert vd. 2017
Excess green index	EGI	$(2xG) - B - R$	Woebbecke vd. 1995
Yeşil Yaprak İndeksi (Green Leaf area index)	GLI	$\frac{(2xG) - B - R}{(2xG) + B + R}$	Hunt. vd. 2013
Üçgensel Yeşillik İndeksi (The Triangular Greenness Index)	TGI	$G - (0.39R - 0.69B)$	Hunt. vd. 2013
Yeşil Bant Oranı	GRI	$\frac{G}{B + G + R}$	Sonnentag vd. 2012
Mavi Bant Oranı	BRI	$\frac{B}{B + G + R}$	Çömert vd. 2017
Kırmızı Bant Oranı	RRI	$\frac{R}{B + G + R}$	Çömert vd. 2017
Normalize Edilmiş Akuatik Bitki İndeksi (The Synthetic NDVI) (Green Red Vegetation Index (GRVI))	NRAVI sNDVI GRVI	$\frac{G - R}{G + R}$	Motohka vd. 2010
Görünür Bölge Atmosferik Dayanıklılık İndeksi	VARI	$\frac{G - R}{B + G + R}$	Gitelson vd. 2002
Excess red vegetation Index	ERVI	$(1.4 x R) - G$	Mao vd. 2003

Çalışma, Şekil 5.15'te gösterildiği gibi 4 temel aşamadan oluşmuştur. Segmentasyon işlemi segmentation sekmesi altında, sınıflandırma işlemi classification sekmesi altında yapılmıştır. Merge sekmesinde ise aynı sınıftaki segmentler birleştirilmiş olup yanlış sınıfa atanan segmentler tespit edilmiştir. Yanlış sınıfa atanana segmentler yeni kurallar tanımlanarak doğru sınıfa atanmıştır. Improve sekmesinde ise sınıflara ataması gerçekleştirilen segmentlerin sınır ve şekil düzeltmeleri gerçekleştirilmiştir.




Şekil 5.15 Çalışma temel aşamaları.

Bundan sonraki aşama yol sınıfının tanımlanması ve bu sınıfa dâhil edilecek segmentlerin belirlenebilmesi için uygun üyelik fonksiyonlarının ve bu fonksiyonlara girilecek değerlerin belirlenmesidir.



Şekil 5.16 Sınıflandırma aşaması.


Şekil 5.16’da gösterilen her bir sınıf için; Şekil 5.17’de verilen “Future View” penceresindeki “Object Features” sekmesi altında bulunan özellikler ve özelliklere ait değerler denenmek suretiyle her bir özelliğin görüntüdeki her bir bantta ve görüntü segmentlerindeki cevapları değerlendirilmiştir. Değerlendirme sonucunda ilgili sınıfa ait ayırımın yakalandığı özellik üzerinde sınıfı en iyi temsil edebilen sınır değerleri tespit edilmiştir. Böylece tespit edilen sınır değerleri uygun üyelik fonksiyonunda kullanılarak sınıflandırmaya devam edilmiş ve bu asama gerçek dünyayı temsil eden en iyi sınıflandırma sağlanana kadar döngüsel olarak devam edilmiştir.



Şekil 5.17 “Class Hierarchy” ve “Feature View” pencereleri ve sınıf ekleme.


Çalışma sadece yolları kapsadığından yollar için sınıflar tayin edilerek yol nesneleri

sınıflandırılmış ve yol dışında kalan nesneler “yol olmayan” diye sınıflandırılmıştır. Bu durum bütün görüntüden yol sınıfı çıkartılarak sağlanmıştır. Yol sınıfları belirlenirken beyaz çatılı binalar ile kırmızı çatılı bina ile yeşil alanlar farklı kural setleri kullanılarak sırasıyla Şekil 5.16’da görüldüğü üzere “White”-“redgreen-redroof” sınıfına atanmıştır. Çalışmada kullanılan kural setleri Şekil 5.18’de gösterilmiştir.




Şekil 5.18 Sınıflandırmada kullanılan kural setleri ve değerleri.

Segmentler sınıflara atandıktan sonra oluşan bütünleşik segmentlerin sınır ve şekil düzeltmeleri yapılmıştır (Şekil 5.19). Örneğin Rel.border to: Seçilen sınıfın ana işlem nesnesiyle paylaşılan bir görüntü nesnesinin kenarlık uzunluğunun toplam kenarlık uzunluğuna oranıdır. Bu özellik ile kendi sınıfında olan segmentin yakınlık derecesi incelenir ve uymayan sınırlar dışarı aktarılır. Bu şekilde uyumsuz olan sınırlar düzeltilmiş olur.




Şekil 5.19 Sınır ve şekil düzeltme.

Sınır ve şekil düzeltmeleri tamamlandıktan sonra çalışma alanına ait yolların tespiti gerçekleştirilmiştir. Tespit edilen yolların görüntüsü Şekil 5.20’de gösterilmiştir.



Şekil 5.20 Tespit edilen yollar (Sol üst: ortofoto – Sağ üst: sınıflara atılmış birleştirilmiş segmentler – Sol alt: Ortofoto ve tespit edilen yollar – Sağ alt: Tespit edilen yollar.

Tespit edilen yollar daha sonra .shp formatında export edilmiştir. Vektör formatındaki yollara, MapInfo yazılımında genelleştirme uygulanmıştır. Şekil 5.21’de genelleştirme sonrasında ortofoto görüntüsü üzerinde gösterile yollar verilmiştir.




Şekil 5.21 Genelleştirme sonrası ortofoto üzerinde tespit edilen yollar.

Sınıflandırma tamamlandıktan sonra mevcut sınıfların yer gerçeği ile ne kadar uyumlu olduğunu belirlemek için tüm çalışma alanında doğruluk analizi yapılmıştır. Doğruluk analizi, sınıflandırmanın doğruluğunu ve güvenilirliğini ölçmek için gerçekleştirilen son işlem adımıdır. Sınıflandırma sonuçlarının doğruluk analizi için ilk olarak eCognition yazılımının sağladığı “Error matrix based on TTA mask” yaklaşımı kullanılmıştır. Seçilen test alanlarının referans değerleri ile sınıflandırma sonucu karşılaştırılarak hata matrisi üretilmiş ve sınıflandırma kalitesi test edilmiştir.

eCognition developer yazılımında ilk önce doğruluk analizi yapılacak alana ait örnek segmentler tanımlanır. Örneklem sayısı belirlenerek her sınıfa ait örnek segmentler gösterilir. Doğruluk analizine daha anlamlı ve daha güvenilir sonuçlar vermek için, doğruluk analizi sırasında seçilecek örneklerin küçük segmentlerden seçilmesi önemlidir. Nesne boyutu azaldıkça, nesnedeki homojenlik paralel olarak artacaktır. Büyük nesneleri örnek olarak seçerken, bu nesneler içindeki farklı spektral özelliklerin ve sınıfların heterojen yapısı sınıflandırma doğruluğunu etkiler. Örnek seçim alanlarının boyutları 180 piksel olarak seçildi.

Örneklem alınmasında örneklemin alındığı evreni temsil etmesi önemlidir. Bu durumda ne kadar, hangi büyüklükteki bir örneklemin evreni temsil edebileceği sorunu ortaya çıkmaktadır. Alınan örneklemin evreni temsil yeterliği bulunmadığında örnekleme hatası olur. Örneklem büyüklüğünü saptamak için evren büyüklüğünün on binin üzerinde olmasından dolayı bu çalışmada örneklem belirlemek için denklem 4.7 kullanılmıştır.

Çalışmada toplam 84212 segment bulunmaktadır. Denklem 4.7'ye göre örneklem sayısı 245 çıkmaktadır. Yazılımda tanımlanan bazı örnek segmentler Şekil 5.22'de gösterilmiştir.



Şekil 5.22 Örnek seçilen bazı segmentler ve sınıflar.

Örneklem sayısı belirlendikten sonra doğruluk analizinde geçilmiştir.

Çizelge 5.2 1.Çalışma (RGB) için nesne tabanlı sınıflandırma sonuçların doğruluk değerlendirmesi

Sınıf	Toplam Segment	Referans Segment Sayısı	Sınıflandırılmış Segment	Doğru Sınıflandırılmış Segment	Üretici Doğruluğu	Kullanıcı Doğruluğu
Road	26817	79	71	61	77.22	85.92
Building	2512	7	7	5	71.43	71.43
Green_area	32112	93	90	75	80.65	83.33
Ground	22771	66	59	47	71.21	79.66
Toplam	84212	245	227	188	76.73	82.82

Sınıflandırma neticesinde farklı sınıflar için; Üretici Doğrulukları %71 ile %80 arasında, Kullanıcı Doğruluğu %71 ile %85 arasında değişim göstermiştir. Üretici ve kullanıcı doğruluğu sırasıyla %77.22 ile %85.92 olarak bulunmuştur.


Çizelge 5.3 1.Çalışma (RGB) için nesne tabanlı sınıflandırma sonuçların Kappa İstatistik tablosu

Sınıf	Kapa İstatistiği
Road	0.7715
Building	0.7000
Green_area	0.8114
Ground	0.7814
Genel Kapa Değeri: 0.7745	

Sınıflandırma neticesinde genel kapa değeri (Kappa index of agreement (KIA)) seviyesi %77 olarak tespit edilmiştir.

eCognition Developer yazılımında doğruluk analizi yapıldıktan sonra MapInfo yazılımında doğruluk analizi yapılmıştır. Bu amaçla ilgili sınıflandırma, eCognition'daki "Dışa Aktar" sekmesinin altındaki "Nesne Şekilleri" düğmesini tıklatarak açılan pencerede yazdırılacak sınıf ve özellikleri seçerek ".SHP" uzantısıyla çıktı alınmıştır. Burada açılan "Nesne Şekli Dışa Aktar" penceresindeki "Çizgi" düğmesi ile çıktının bir çizgi verisi olacağı şekilde seçilmiştir. Böylece, raster sınıflandırması vektör verilerine dönüştürülmüş ve karşılaştırma için kullanılacak MapInfo yazılımı için uygun bir formata dönüştürülmüştür. Uygulamanın bir sonraki adımı, MapInfo yazılımı kullanılarak CBS ortamında yapılan çalışmaları değerlendirmektir. Tespit edilen yollar .shp formatında export edilmiştir. Daha sonra MapInfo yazılımında sırasıyla "feature to polygon", "polygon to raster", "reclassfy" ve "raster to point" işlemleri yapılmıştır.


MapInfo yazılımında doğruluk analizinde yol ve yol olmayan iki sınıf oluşturulmuştur. Yol olan sınıfa 1, yol olmayan sınıflara 0 tanımlanmıştır (Şekil 5.23).



Şekil 5.23 Referans kabul edilen vektöre harita ve sınıflar (1:yol – 0: yol olmayan).

Karşılaştırmak için ilk olarak örneklem seçilmiştir. Örneklem uzayı yani toplam kütle (N) "feature to polygon" işleminde oluşturulan tüm alandaki polygonlar seçilmiştir. Bu Çalışma için hedef kitledeki birey sayısı (ana kütle sayısı) yani "N" 94578591 oluşmuştur. Denklem 4.7'ye göre örneklem sayısı "n" 2988 hesaplanmıştır.

Karşılaştırma verisi olarak daha önce klasik metotlarla üretilen vektör harita kullanılmıştır. Vektör harita referans kabul edilmiştir. Çalışma alanına hem rastgele nokta (random point) hem de belirli aralıklarla (fishnet) ile örneklem noktaları denenmiştir. Fishnet yönteminde noktalar çok sık olduğu için random point yöntemi tercih edilmiştir (Şekil 5.24).



Şekil 5.24 Referans kabul edilen vektöre harita ve random point (2988 tane).

Rastgele atılan aynı noktalar, tespit edilen yolların olduğu harita üzerine de atılmıştır. İlk olarak bu işlem içinde örneklem tespit edilmiştir. Örneklem sayısı belirlendikten sonra bu sayı kadar rastgele nokta atılmıştır. Atılan bu noktaların, referans verisindeki konumlarının tespit edilen yolların oluşturduğu vektör haritadaki durumu incelenmiştir. Bunun için;

Gerçek pozitif (TP): yol noktaları doğru sınıfa (Evet)

Gerçek negatif (TN): yol olmayan noktalar yol olmayan sınıfa (Hayır)

Yanlış pozitif (FP): yol olmayan noktalar yol sınıfa (Evet)

Yanlış negatif (FN): yol olan noktalar yol olmayan sınıfa (Hayır)

baz alınara denklem 4.8-4.12 uygulanarak hesaplamalar yapılmıştır ve sonuçlar çizelge 5.4’te gösterilmiştir.

Çizelge 5.4 1.Çalışma (RGB) için doğruluk analizi

Tahmin				Tahmin				Toplam
		P	N			P	N	
Gerçekte	P	TP	FN	Gerçekte	P	850	349	1199
	N	FP	TN		N	191	1598	1789
		Toplam				1041	1947	

Çizelge 4.4’e göre Doğruluk, Hassasiyet, Duyarlılık, F_1 Puanı ve Özgünlük sırasıyla; 0.8192 – 0.8165 – 0.7089 – 0.7589 – 0.8932 hesaplanmıştır.

5.2 Çalışma 2 (Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer kampüsü-RG-NIR Görüntüler)

İkinci çalışma alanı olarak Şekil 4.3’de bulunan Afyon Kocatepe Üniversitesi Ahmet Necdet Sezer Kampüsü seçilmiştir. Bu alanda yapılan ilk çalışmada RGB, ikinci çalışmada ise RG-NIR görüntüleri kullanılmıştır.


5.2.1 Veri Temini

Çalışma alanı yaklaşık 18 hektarlık bir alandan oluşmaktadır. Çalışma alanına ait hava görüntüleri 40 metre yükseklikten Şekil 4.2’de gösterilen Phantom Pro 3 İHA’ya entegre edilmiş Mapir survey 3 kamera (Şekil 4.6) ile nadir konumdan ve bindirmeli olarak çekilmiştir. Toplam 244 fotoğraf çekilmiş olup tamamı kullanılmıştır. Araziye 6 adet yer kontrol noktası (YKN) tesis edilmiş olup yer kontrol noktalarının ölçümü GPS ile gerçekleştirilmiştir.

5.2.2 Fotogrametrik Süreç

Bu çalışmada kullanılan fotoğraflar RG-NIR bantına sahiptir. Özellikle NIR bantı ile bitki örtüsü daha kolay tespit edilebilmektedir. Bu çalışmada NIR bantının nesne tespitine etkisi araştırılmıştır.

İlk olarak bitki örtüsü yansımalarını ölçmek için kullanılan görüntüleri kalibre etmemiz gerekmektedir. Güneş, Dünya yüzeyindeki nesneler tarafından yansıtılan geniş bir ışık spektrumu yayar. Kameralar; bu yansıyan ışığı, kamera sensörünün duyarlı olduğu dalga boylarında yakalamak amacıyla kullanılır. Kullanılan sensörler, 400-1200nm arasında Görünür ve Yakın Kızılötesi spektrumunda hassas olan silikon esaslıdır (Şekil 5.25).




Şekil 5.25 RG-NIR dalga boyları.

Kameralardaki özle filtreler sayesinde elektromanyetik spektrumdaki belirli bölgelerindeki yansımaları yakalayabilir.

Örneğin, kameranın filtresi 650nm tepe dalga boyuna sahip 25nm genişliğinde bir bant seçerse, yalnızca güneş tarafından yayılan "kırmızı" ışığı yakalar. Böylece görüntüdeki her piksel, "kırmızı filtreden" geçmesine izin verilen ışığın yüzdesini oluşturur.


Pikseller, görüntü bit hızına bağlı olarak minimum ile maksimum arasında değişen bir değere sahiptir. Bit hızı ne kadar yüksek olursa görüntüde saklanabilecek bilgi miktarı da o kadar fazla olur. Bir sensör, her görüntüyü bir RAW (ham) formatında yakalar ve RAW olarak kaydeder veya daha yaygın bir formata dönüştürür. Survey3 kameralar, RGB kanalı başına 16 bit RAW fotoğraf çeker, yani 16 bit (65.536) piksel ve 0 ile 65.535 piksel aralığı vardır. Fotoğraf makinesi 8 bitlik bir JPG kaydettiğinde pikselleri sıkıştırır ve yalnızca 0 ile 255 arasında bir aralık bırakır.

Ayrıca kamera ayarlarının (deklanşör hızı, ISO, EV) her piksel için maksimum piksel değerine ulaşmayacak şekilde ayarlandığından emin olunması önemlidir. Bir piksel normalde maksimum değerden yüksekse istenen bilgiler kaybolur. Survey3 kameralarındaki görüntüler ilk çekildiğinde karanlık görünmektedir (Şekil 5.26). Piksellerin maksimum değere ulaşmasını önlemek için varsayılan ayarları belirlendiği için bu normal bir durumdur.



Şekil 5.26 Mapir Survey 3 kamera ile çekilmiş örnek resim.

Bu durum kalibrasyon ihtiyacını ortaya çıkarmaktadır. Her pikselde bir yansıtma yüzdesi yakaladığımızdan, doğru olup olmadığını anlamamız gerekmektedir. Bilinen bir yansıtma değeri kullanarak her pikseli kalibre etmenin yerine her ölçümden hemen önce bir spektrometre (kalibre edilmiş bir laboratuvar cihazı) tarafından artan dalga boylarında ölçülen 3 hedef içeren (RG-NIR) Şekil 5.27'deki MAPIR kamera yansıtma kalibrasyonu levhasının Şekil 5.28'de gösterildiği gibi fotoğrafının çekilmesi gerekmektedir.



Şekil 5.27 Mapir Survey 3 kamera ile çekilmiş örnek kalibrasyon levhası.


Kalibrasyon levhasının örnek fotoğraf çekimi Şekil 4.27’de verilmiştir.



Şekil 5.28 Örnek kalibrasyon levhası fotoğraf çekimi.


Ardından yakalanan hedef görüntünün piksel değerleri, hedeflerin bilinen yansımaya değerleri ile karşılaştırılır. Bu bilgiler, MAPIR Kamera Kontrol yazılımında piksel değerlerini dönüştürülüyor ve böylece görüntüler kalibre edilir.

Kalibrasyon için iki yöntem bulunmaktadır. Bunlardan ilki araziden kalibrasyon levhası görüntüsündeki QR kodunun algılanması ile yapılan kalibrasyon. QR kodunu algılamak için hiçbir görüntü kullanılamıyorsa ikinci yöntem uygulanır (Şekil 5.29). Yazılım otomatik olarak güneşli bir günde alınan sabit kodlanmış değerleri kullanarak fotoğrafları kalibre etmektedir. Sabit kodlanmış değerler kullanılırsa küçük bir yanlışlık olabilir, bu nedenle en iyi sonuçlar için ölçümden kısa bir süre önce kalibrasyon levhasının fotoğrafları çekilmelidir.




Şekil 5.29 Fotoğrafların kalibre edilmesi.

Fotoğraflar kalibre edildikten sonra ortofoto üretme adımına geçilebilir. Aynı anda birden çok sensör kullanarak görüntü yakalıyorsanız, yazılımımızın birden çok sensörün hizalanmasını desteklediğinden emin olmanız gerekmektedir. Bu yüzden birden çok sensör görüntüsünün işlenmesine olanak sağlayan Pix4D Mapper yazılımı kullanılmıştır. Görüntüleri Pix4D yazılımına aktarırken doğru bantların bulunduğu dikkat edilmelidir (Şekil 5.30). Eğer çalışmadan önce kalibrasyon levhasının fotoğrafları çekildiyse her bantın yansıma faktörü değeri (reflectance factor value) girilmelidir. Eğer bilinmiyorsa kameranın üretici değerleri kalibrasyon sırasında işlenmektedir. Bu çalışmada kalibrasyon levhasının fotoğrafları çekilmediği için bu adım yapılmamıştır.



Şekil 5.30 Fotoğrafların Pix4D yazılımına aktarılması (RG-NIR).

İHA ile çekilen görüntüler, Pix4D yazılımı aracılığıyla fotogrametrik olarak dengelemesi yapılmıştır. Dengeleme sonunda araziden ölçümü yapılan YKN kullanılarak arazi koordinatlarına dönüştürülmüştür. Daha sonra çalışma alanının ortofotosu üretilmiştir. Üretilen ortofotoların yer örneklem aralığı (GSD) 1.92 cm çözünürlüğe sahiptir. Çalışma alanına ait ortofoto ve DSM Şekil 5.31’de gösterilmiştir. Pix4D yazılımında fotogrametrik değerlendirme yapıldıktan sonra Omega, Phi, Kappa değerleri sırasıyla 0.338 - 0.625 - 0.139 elde edilmiştir.



Şekil 5.31 Pix4D yazılımında üretilen ürünler (RG-NIR) (Sol: Ortofoto – Sağ: DSM).


5.2.3 Nesne Tabanlı Sınıflandırma

Bu çalışmada uygulanan nesne tabanlı sınıflandırma çalışması; segmentasyon, sınıflandırma ve doğruluk analizlerinde oluşmaktadır. Segmentasyon aşamasında ilk çalışmada detaylı anlatılan ölçek, şekil ve bütünlük parametrelerinin belirlenmesi işlemleri aynı şekilde yapılmıştır.

Segmentasyon için çoklu çözünürlüklü segmentasyon seçilmiştir. Çeşitli denemelerden sonra çizelge 5.5’te verilen değerler seçilmiştir. Segmentasyon görüntüsü Şekil 5.32’de gösterilmiştir.

Çizelge 5.5 2.Çalışma (RG-NIR) için seçilen segmentasyon değerleri

Parametre	Değer
Ölçek	80
Şekil	0.4
Bütünlük	0.6



Şekil 5.32 2.Çalışma için (RG-NIR) segmentasyon.


Segmentasyon işleminden sonra tüm alan detaylı bir şekilde incelenmiş ve inceleme sonucu çeşitli sebeplerle bütünlüğü bozulmuş veya başka nesneye ait segmente karışmış olan bazı nesneler yazılımın elle nesne ayırma ve nesne birleştirme özellikleri kullanılarak düzeltilmiştir.

Segmentasyon işleminden sonra sınıflandırma işlemine geçilmiştir. Bu aşamada çeşitli bant kombinasyonları oluşturmuş ve karşılık gelen aralıktaki nesneler gri renk tonunda elde edilen aralıktan istenen detaylar çıkartılmıştır. İlk çalışmada RGB bantlar kullanılarak çizelge 5.1’deki bant kombinasyonları kullanılmıştır. Bu çalışmada hem çizelge 5.1’deki hem de çizelge 5.6’daki bantlar kullanılmıştır.

Çizelge 5.6 Literatürdeki bazı RG-NIR bant indeksleri


İsim	Kısaltma	Formül	Referans
infrared percentage vegetation index	IPVI	$\frac{NIR}{NIR - Red}$	Crippen R E 1990
difference vegetation index	DVI	$(NIR - Red)$	Richardson J. ve Weigand 1977
Difference Difference Vegetation Index	DDVI	$[(2 \times NIR - Red) - (Green - Blue)]$	Eisfelder 2009
Ratio Vegetation Index	RVI	$\frac{Red}{NIR}$	Xue vd. 2017
Normalised Difference Vegetation Index	NDVI	$\frac{NIR - Red}{NIR + Red}$	Rouse Jr. Vd. 1974
Transformed Difference Vegetation Index	TDVI	$1.5 \times \frac{NIR - Red}{\sqrt{NIR^2 + R + 0.5}}$	Bannari vd. 2002
Normalized difference water index	NDWI	$\frac{Green - NIR}{Green + NIR}$	McFeeters vd. 1996

Çeşitli bant kombinasyonları belirlendikten sonra sınıflandırma işlemine geçilmiştir. Sınıflandırma, birleştirme ve şekil ve sınır düzeltme işlemleri Şekil 5.33’de gösterilmiştir.



Şekil 5.33 2.Çalışma için (RG-NIR) sınıflandırma aşamaları.

Çalışmada elde edilen sınıflandırma sonuç görüntüleri Şekil 5.34’de gösterilmiştir.



Şekil 5.34 2.Çalışma için (RG-NIR) sınıflandırma sonuçları.

Sınıflandırma çalışması bittikten sonra doğruluk analizine geçilmiştir. Doğruluk analizi ilk çalışmada olduğu gibi hem eCognition yazılımında TTA örneklerine dayalı hata matrisi (Error matrix based on TTA samples)" yöntemi ile hem de Mapinfo yazılımında noktaların konumu araştırılarak yapılmıştır.

İlk yöntem için toplam 14856 segment araştırılmıştır. Denklem 4.7’ye göre örneklem sayısı 135 belirlenmiştir. Doğruluk analizi sonucu çizelge 5.7’de gösterilmiştir.

Çizelge 5.7 2.Çalışma için (RG-NIR) nesne tabanlı sınıflandırma doğruluk analizi

Sınıf	Toplam segment	Referans segment sayısı	Sınıflandırılmış segment	Doğru Sınıflandırılmış segment	Üretici doğruluğu	Kullanıcı doğruluğu
Road	4410	41	38	33	80.49	86.84
Building	1675	15	13	11	73.33	84.62
Green_area	5115	46	43	38	82.61	88.37
Ground	3656	33	31	27	81.82	87.10
Toplam	14856	135	125	110	81.48	88.00

Çizelge 5.8 2.Çalışma için (RG-NIR) nesne tabanlı sınıflandırma için kapa istatistiği

Sınıf	Kapa İstatistiği
Road	0.8615
Building	0.8214
Green_area	0.8714
Ground	0.8614
Genel Kapa Değeri: 0.8545	

Sınıflandırma neticesinde genel kapa değeri (Kappa index of agreement (KIA)) seviyesi %85 olarak tespit edilmiştir. eCognition Developer yazılımında doğruluk analizi yapıldıktan


sonra MapInfo yazılımında doğruluk analizi yapılmıştır. Karşılaştırmak için ilk olarak örneklem seçilmiştir. Örneklem uzayı yani toplam kütle (N) “feature to polygon” işleminde oluşturulan tüm alandaki polygonlar seçilmiştir. Bu Çalışma için hedef kitledaki birey sayısı (ana kütle sayısı) yani “N” 6755613.643 oluşmuştur. Denklem 4.7’ye göre örneklem sayısı “n” 1067 hesaplanmıştır. Karşılaştırma verisi olarak daha önce klasik metotlarla üretilen vektör harita kullanılmıştır. Vektör harita referans kabul edilmiştir. Çalışma alanına rastgele nokta (random point) ile örneklem noktaları denenmiştir.

Çizelge 5.9 2.Çalışma için (RG-NIR) nesne tabanlı sınıflandırma doğruluk sonuçları

		Tahmin				Tahmin		Toplam
Gerçekte		P	N	Gerçekte		P	N	
	P	TP	FN		P	425	64	489
	N	FP	TN		N	89	489	578
		Toplam				514	553	

Denklem 4.8-4.9-4.10-4.11-4.12’e göre gerekli hesaplamalar yapılmıştır. Çizelge 5.9’a göre Doğruluk, Hassasiyet, Duyarlılık, *F1Puanı* ve Özgünlük sırasıyla; 0.8566 – 0.8268 – 0.8691 – 0.8475 – 0.8460 hesaplanmıştır.

5.3 Çalışma 3: İzmir-Foça / Ilıpınar (RG-NIR-Re (Rededge))



Şekil 5.35 İzmir ilinin konumu ve coğrafi koordinatları.

Bu çalışmada Şekil 5.35’te konumu ve coğrafi koordinatları gösterilen İzmir ili Ilıpınar Köyü sınırları içerisindeki Şekil 5.36’da görüldüğü üzere yapılaşmanın az olduğu alanda NIR ve Re bantların sınıflandırmaya etkisi araştırılmıştır.



Şekil 5.36 Ilıpınar Köyü sınırları içerisindeki çalışma alanı ve coğrafi koordinatları.

5.3.1 Veri Temini

Çalışma alanı yaklaşık 10 hektarlık bir alandan oluşmaktadır. Çalışma alanına ait hava görüntüleri 100 metre yükseklikten Parrot Bluegrass İHA'ya (Şekil 4.5) entegreli RG-NIR-Re bantlara sahip Parrot Sequoia+ kamera (Şekil 4.5) ile çekilmiştir. Toplam 440 fotoğraf çekilmiş olup tamamı kullanılmıştır.

5.3.2 Fotogrametrik Süreç

Bu çalışmada kullanılan fotoğraflar RG-NIR-Re bantlarına sahiptir. Özellikle NIR bantı ile bitki örtüsü daha kolay tespit edilebilmektedir. Ayrıca 'Red Edge (Kırmızı Kenar)' vejetasyonun (bitki örtüsünün) aniden yansıdığı elektromanyetik spektrumun 680-740 nm aralığını belirtmektedir. Bu aralıkta, bitki örtüsüne ait iki optik etki söz konusudur:

- a) spektrumun kırmızı bölgesinde güçlü klorofil yutulmasından dolayı meydana gelen düşük yansımaya
- b) yakın kızılötesi bölgede bitki örtüsüne ait yaprakların sebep olduğu yüksek saçılmadan dolayı oluşan yüksek yansımaya (Dawson ve Curran 1998).


Bu çalışmada kullanılan kamera (Parrot Sequoia+ kamera) görüntülerin bir önceki çalışmada kullanılan kamera (Mapir Survey 3) görüntüleri gibi ikincil bir yazılım ile kalibre edilmesine gerek yoktur. Fakat bu kamera içinde her ölçümden hemen önce bir spektrometre (kalibre edilmiş bir laboratuvar cihazı) tarafından artan dalga boylarında

ölçülen hedef içeren (RG-NIR-Re) Şekil 5.37’de gösterilen kalibrasyon levhasının Şekil 5.28’de gösterildiği gibi bir fotoğrafının çekilmesi gerekmektedir.



Şekil 4.37 Parrot Sequoia+ kamera ile çekilmiş örnek kalibrasyon levhası.

Ortofoto üretiminde aynı anda birden çok sensör kullanarak görüntü yakalıyorsanız, yazılımınızın birden çok sensörün hizalanmasını desteklediğinden emin olmanız gerekmektedir. Bu yüzden birden çok sensör görüntüsünün işlenmesine olanak sağlayan Pix4D Mapper yazılımı kullanılmıştır. Görüntüleri Pix4D yazılımına aktarırken doğru bantların bulunduğuna dikkat edilmelidir (Şekil 5.38). Eğer çalışmadan önce kalibrasyon levhasının fotoğrafları çekildiyse her bantın yansımaya faktörü değeri (reflectance factor value) girilmelidir. Eğer bilinmiyorsa kameranın üretici değerlerinin sabit yansımaya değerleri kullanılmalı.




Şekil 5.38 3.Çalışma için (RG-NIR-Re) fotoğrafların yazılıma eklenmesi.

Bu çalışma için yansıma değerleri çizelge 5.10’da verilmiştir.


Çizelge 5.10 Parrot Sequoia+ kamera yansıma değerleri

Bant	Reflactance factor value
R	0.218
G	0.18
Re	0.269
NIR	0.372



Şekil 5.39 Parrot Sequoia+ kamera yansıma değerlerinin tanıtılması ($g=0.18$).

İHA ile çekilen görüntüler, Pix4D yazılımı aracılığıyla fotogrametrik olarak dengelemesi yapılmıştır. Üretilen ortofotoların yer örneklem aralığı (GSD) 6.52 cm çözünürlüğe sahiptir. Çalışma alanına ait ortofoto ve DSM Şekil 5.40’da gösterilmiştir. Pix4D yazılımında fotogrametrik değerlendirme yapıldıktan sonra Omega, Phi, Kappa değerleri sırasıyla 0.129 - 0.128 - 0.072 elde edilmiştir.



Şekil 5.40 3.Çalışmaya ait her bant için ortofoto (sol) ve DSM (sağ).


5.3.3 Nesne Tabanlı Sınıflandırma

Bu çalışmada uygulanan nesne tabanlı sınıflandırma çalışması; segmentasyon, sınıflandırma ve doğruluk analizlerinde oluşmaktadır. Segmentasyon aşamasında ilk çalışmada detaylı anlatılan ölçek, şekil ve bütünlük parametrelerinin belirlenmesi işlemleri aynı şekilde yapılmıştır.

Segmentasyon için çoklu çözünürlüklü segmentasyon seçilmiştir. Çeşitli denemelerden sonra çizelge 5.11’de verilen değerler seçilmiştir. Segmentasyon görüntüsü Şekil 5.41’de gösterilmiştir.

Çizelge 5.11 2. Çalışma alanı (RG-NIR-Re) için seçilen segmentasyon değerleri

Parametre	Değer
Ölçek	120
Şekil	0.3
Bütünlük	0.7



Şekil 5.41 3.Çalışma için (RG-NIR-Re) segmentasyon.


Segmentasyon işleminden sonra tüm alan detaylı bir şekilde incelenmiş ve inceleme sonucu çeşitli sebeplerle bütünlüğü bozulmuş veya başka nesneye ait segmentle karışmış olan bazı nesneler yazılımın elle nesne ayırma ve nesne birleştirme özellikleri kullanılarak düzeltilmiştir.

Segmentasyon işleminden sonra sınıflandırma işlemine geçilmiştir. Bu aşamada çeşitli bant kombinasyonları oluşturmuş ve karşılık gelen aralıktaki nesneler gri renk tonunda elde edilen aralıktan istenen detaylar çıkartılmıştır. İlk çalışmada RGB bantlar kullanılarak çizelge 5.1’deki bant kombinasyonları kullanılmıştır. Bu çalışmada hem

çizelge 5.1'deki hem de çizelge 5.6'daki bantlara ek olarak denklem 5.19'daki bant kombinasyonu kullanılmıştır.


$$NDVI - RE = \frac{Re-R}{Re+R} \quad (5.19)$$

Çeşitli bant kombinasyonları belirlendikten sonra sınıflandırma işlemine geçilmiştir. Sınıflandırma, birleştirme ve şekil ve sınır düzeltme işlemleri Şekil 5.14'de gösterildiği gibi yapılmıştır. Sınıflandırma aşamasında kullanılan kural setleri Şekil 5.42'de gösterilmiştir.



Şekil 5.42 3.Çalışma için (RG-NIR) sınıflandırma kural setleri.

Şekil 5.43'de sınıflandırma sonucu gösterilmiştir.



Şekil 5.43 3. Çalışma için (RG-NIR-Re) sınıflandırılmış görüntü.

Sınıflandırma çalışması bittikten sonra doğruluk analizine geçilmiştir. Doğruluk analizi diğer çalışmalarda olduğu gibi hem eCognition yazılımında TTA örneklerine dayalı hata matrisi “(Error matrix based on TTA samples)” yöntemi ile hem de Mapinfo yazılımında noktaların konumu araştırılarak yapılmıştır.

İlk yöntem için toplam 9256 segment araştırılmıştır. Denklem 4.7’ye göre örneklem sayısı 121 belirlenmiştir. Doğruluk analizi sonucu çizelge 5.12 ve 5.13’de gösterilmiştir.

Çizelge 5.12 3.Çalışma için (RG-NIR-Re) nesne tabanlı sınıflandırma doğruluk analizi

Sınıf	Toplam segment	Referans segment sayısı	Sınıflandırılmış segment	Doğru Sınıflandırılmış segment	Üretici doğruluğu	Kullanıcı doğruluğu
Road	1180	24	22	20	83.33	90.91
Building	48	3	3	3	100.00	100.00
Green_area	7115	95	91	85	89.47	93.41
Ground	913	13	10	8	61.54	80.00
Toplam	9256	135	126	116	85.93	92.06

Çizelge 5.13 3.Çalışma için (RG-NIR-Re) nesne tabanlı sınıflandırma için kapa istatistiği

Sınıf	Kapa İstatistiği
Road	0.9125
Building	0.9456
Green_area	0.9512
Ground	0.8114
Genel Kapa Değeri: 0.9014	


Sınıflandırma neticesinde genel kapa değeri (Kappa index of agreement (KIA)) seviyesi %90 olarak tespit edilmiştir. eCognition Developer yazılımında doğruluk analizi yapıldıktan sonra MapInfo yazılımında doğruluk analizi yapılmıştır. Karşılaştırmak için ilk olarak örneklem seçilmiştir. Örneklem uzayı yani toplam kütle (N) “feature to polygon” işleminde oluşturulan tüm alandaki polygonlar seçilmiştir. Bu Çalışma için hedef kitledeki birey sayısı (ana kütle sayısı) yani “N” 2715373 oluşmuştur. Denklem 4.7’ye göre örneklem sayısı “n” 867 hesaplanmıştır. Karşılaştırma verisi olarak daha önce klasik metotlarla üretilen vektör harita kullanılmıştır. Vektör harita referans kabul edilmiştir. Çalışma alanına rastgele nokta (random point) ile örneklem noktaları denenmiştir.

Çizelge 5.14 3.Çalışma için (RG-NIR-Re) nesne tabanlı sınıflandırma doğruluk sonuçları

		Tahmin				Tahmin		Toplam
		P	N			P	N	
Gerçekte	P	TP	FN	Gerçekte	P	374	51	425
	N	FP	TN		N	45	397	442
		Toplam				419	448	

Denklem 4.8-4.9-4.10-4.11-4.12'e göre gerekli hesaplamalar yapılmıştır. Çizelge 5.14'e göre Doğruluk, Hassasiyet, Duyarlılık, *F1Puanı* ve Özgünlük sırasıyla; 0.8893 – 0.8926 – 0.8800 – 0.8863 – 0.8982 hesaplanmıştır.

5.4 Çalışma 4: Yozgat / Sorgun (RGB)



Şekil 5.44 Yozgat ilinin konumu ve coğrafi koordinatları.

Bu çalışmada Şekil 5.44'te konumu ve coğrafi koordinatları gösterilen Yozgat-Sorgun'da bulunan karayolu seçilmiştir.



Şekil 5.45 Yozgat – Sorgun karayolu.


Bu çalışmada amaç, Şekil 5.45'te gösterilen yapılaşmanın orta seviyede olduğu, bitki örtüsünün az olduğu ayrıca hem asfalt hem de bozuk satırlı yolların bulunduğu alanı incelemektir. RGB görüntülerle geometrik olarak düz hat olan karayollarının tespiti incelenmiştir.

5.4.1 Veri Temini

Çalışma alanı yaklaşık 70 hektarlık bir alandan oluşmaktadır. Çalışma alanına ait hava görüntüleri 215 metre yükseklikten Sensefly Ebee Plus İHA'ya entegreli RGB bantlara sahip S.O.D.A kamera (Şekil 4.3) ile çekilmiştir. Toplam 312 fotoğraf çekilmiş olup tamamı kullanılmıştır. Araziye 16 adet yer kontrol noktası (YKN) tesis edilmiş olup yer kontrol noktalarının ölçümü GPS ile gerçekleştirilmiştir.

5.4.2 Fotogrametrik Süreç

İHA ile çekilen görüntüler, Pix4D yazılımı aracılığıyla fotogrametrik olarak dengelemesi yapılmıştır. Dengeleme sonunda araziden ölçümü yapılan YKN kullanılarak arazi koordinatlarına dönüştürülmüştür. Daha sonra çalışma alanının ortofotosu üretilmiştir. Üretilen ortofotoların yer örneklem aralığı (GSD) 6,1 cm çözünürlüğe sahiptir. Çalışma alanına ait ortofoto Şekil 5.46'da gösterilmiştir. Pix4D yazılımında fotogrametrik değerlendirme yapıldıktan sonra Omega, Phi, Kappa değerleri sırasıyla 0.512-0.712-2.145 elde edilmiştir.



Şekil 5.46 4.Çalışma için (RGB) ortofoto.

5.4.3 Nesne Tabanlı Sınıflandırma


Bu çalışmada uygulanan nesne tabanlı sınıflandırma çalışması; segmentasyon, sınıflandırma ve doğruluk analizlerinde oluşmaktadır. Segmentasyon aşamasında ilk çalışmada detaylı anlatılan ölçek, Şekil ve bütünlük parametrelerinin belirlenmesi işlemleri aynı şekilde yapılmıştır.

Segmentasyon için çoklu çözünürlüklü segmentasyon seçilmiştir. Çeşitli denemelerden

sonra çizelge 5.15’de verilen değerler seçilmiştir. Segmentasyon görüntüsü Şekil 5.47’de gösterilmiştir.

Çizelge 5.15 4. Çalışma (RGB) için seçilen segmentasyon değerleri

Parametre	Değer
Ölçek	100
Şekil	0.3
Bütünlük	0.7




Şekil 5.47 4. Çalışma için (RGB) segmentasyon.

Segmentasyon işleminden sonra tüm alan detaylı bir şekilde incelenmiş ve inceleme sonucu çeşitli sebeplerle bütünlüğü bozulmuş veya başka nesneye ait segment ile karışmış olan bazı nesneler yazılımın elle nesne ayırma ve nesne birleştirme özellikleri kullanılarak düzeltilmiştir.


Segmentasyon işleminden sonra sınıflandırma işlemine geçilmiştir. Bu aşamada çeşitli bant kombinasyonları oluşturmuş ve karşılık gelen aralıktaki nesneler gri renk tonunda elde edilen aralıktan istenen detaylar çıkartılmıştır. İlk çalışmada RGB bantlar kullanılarak çizelge 4.1’deki bant kombinasyonları kullanılmıştır.

Çeşitli bant kombinasyonları belirlendikten sonra sınıflandırma işlemine geçilmiştir. Sınıflandırma, birleştirme ve şekil ve sınır düzeltme işlemleri Şekil 5.14’de gösterildiği gibi yapılmıştır. Sınıflandırma aşamasında kullanılan kural setleri Şekil 5.48’de gösterilmiştir.



Şekil 5.48 4. Çalışma için (RGB) sınıflandırma aşamaları.

Şekil 5.49’da sınıflandırma sonucu gösterilmiştir.



Şekil 5.49 4. Çalışma için (RGB) sınıflandırılmış görüntü.

Sınıflandırma çalışması bittikten sonra doğruluk analizine geçilmiştir. Doğruluk analizi diğer çalışmalarda olduğu gibi hem eCognition yazılımında TTA örneklerine dayalı hata matrisi “(Error matrix based on TTA samples)” yöntemi ile hem de Mapinfo yazılımında noktaların konumu araştırılarak yapılmıştır.

İlk yöntem için toplam 14256 segment araştırılmıştır. Denklem 4.7’ye göre örneklem sayısı 136 belirlenmiştir. Doğruluk analizi sonucu çizelge 5.16 ve 5.17’de gösterilmiştir

Çizelge 5.16 4. Çalışma için (RGB) nesne tabanlı sınıflandırma doğruluk analizi

Sınıf	Toplam segment	Referans segment sayısı	Sınıflandırılmış segment	Doğru Sınıflandırılmış segment	Üretici doğruluğu	Kullanıcı doğruluğu
Road	5166	48	43	37	77.08	86.05
Building	2132	21	18	15	71.43	83.33
Ground	6959	67	61	50	74.63	81.97
Toplam	14257	136	122	102	75.00	83.61

Çizelge 5.17 4. Çalışma için (RGB) nesne tabanlı sınıflandırma için kapa istatistiği

Sınıf	Kapa İstatistiği
Road	0.7814
Building	0.8356
Ground	0.8145
Genel Kapa Değeri: 0.7958	

Sınıflandırma neticesinde genel kapa değeri (Kappa index of agreement (KIA)) seviyesi %79 olarak tespit edilmiştir. eCognition Developer yazılımında doğruluk analizi yapıldıktan sonra MapInfo yazılımında doğruluk analizi yapılmıştır. Karşılaştırmak için ilk olarak örneklem seçilmiştir. Örneklem uzayı yani toplam kütle (N) “feature to polygon” işleminde oluşturulan tüm alandaki polygonlar seçilmiştir. Bu Çalışma için hedef kitledeki birey sayısı (ana kütle sayısı) yani “N” 4847861 oluşmuştur. Denklem 4.7’ye göre örneklem sayısı “n” 1254 hesaplanmıştır. Karşılaştırma verisi olarak daha önce klasik metotlarla üretilen vektör harita kullanılmıştır. Vektör harita referans kabul edilmiştir. Çalışma alanına rastgele nokta (random point) ile örneklem noktaları denenmiştir.


Çizelge 5.18 4. Çalışma için (RGB) nesne tabanlı sınıflandırma doğruluk sonuçları

Tahmin				Tahmin				
		P	N			P	N	Toplam
Gerçekte	P	TP	FN	Gerçekte	P	434	213	647
	N	FP	TN		N	98	509	607
Toplam						532	722	

Denklem 4.8-4.9-4.10-4.11-4.12’e göre gerekli hesaplamalar yapılmıştır. Çizelge 5.18’e göre Doğruluk, Hassasiyet, Duyarlılık, *F1Puanı* ve Özgünlük sırasıyla; 0.7520 – 0.8158 – 0.6708 – 0.7362 – 0.8386 hesaplanmıştır.

5.5 Çalışma 5: Bioley-Orjulaz / İsviçre (Test alanı) (RGB-NIR-Re)

Bu çalışmada Şekil 5.50’de konumu ve coğrafi koordinatları gösterilen İsviçre sınırları içerisinde yapılaşmanın az olduğu, bitki örtüsü detayının fazla olduğu bir alanda RGB-NIR ve Re bantların sınıflandırmaya etkisi araştırılmıştır.



Şekil 5.50 Bioley-Orjulaz / İsviçre ve coğrafi koordinatları (46°37'1.36"N - 6°36'25.15"E).

Aynı zamanda bundan önceki çalışmalarda kullanılan kural setleri test verisi üzerinde ne kadar doğru işleneceği araştırılmıştır.


5.5.1 Veri Temini

Çalışma alanı yaklaşık 35 hektarlık bir alandan oluşmaktadır. Çalışma alanına ait hava görüntüleri 30 metre yükseklikten Sensefly Ebee X İHA’ya entegreli RGB-NIR-Re bantlara sahip MicaSense RedEdge-M kamera (Şekil 4.5) ile çekilmiştir. Toplam 1803 fotoğraf çekilmiş olup tamamı kullanılmıştır.

5.5.2 Fotogrametrik Süreç


Bu çalışmada kullanılan fotoğraflar RG-NIR-Re bantlarına sahiptir. Özellikle NIR bantı ile bitki örtüsü daha kolay tespit edilebilmektedir. Ayrıca ‘Red Edge (Kırmızı Kenar)’ bantının sınıflandırmaya etkisi araştırılmıştır.

Bu çalışmada kullanılan kamera (RedEdge-M) görüntülerinin, 5.2 başlığı altında verilen çalışmada kullanılan kamera görüntülerine ikincil bir yazılımla uygulanan librasyona ihtiyacı yoktur. Fakat bu kamera içinde her ölçümden hemen önce bir spektrometre (kalibre edilmiş bir laboratuvar cihazı) tarafından artan dalga boylarında ölçülen hedef içeren (RGB-NIR-Re) kalibrasyon levhasının Şekil 5.28’de gösterildiği gibi bir fotoğrafının çekilmesi gerekmektedir (Şekil 5.51).



Şekil 5.51 5. Çalışma için (RGB-NIR-Re) kalibrasyon levhaların fotoğrafları.

Ortofoto üretiminde aynı anda birden çok sensör kullanarak görüntü yakalıyorsanız, yazılımınızın birden çok sensörün hizalanmasını desteklediğinden emin olmanız gerekmektedir. Bu yüzden birden çok sensör görüntüsünün işlenmesine olanak sağlayan Pix4D Mapper yazılımı kullanılmıştır. Görüntüleri Pix4D yazılımına aktarırken doğru bantların bulunduğuna dikkat edilmelidir (Şekil 5.52). Eğer çalışmadan önce kalibrasyon levhasının fotoğrafları çekildiyse her bantın yansıma faktörü değeri (reflectance factor value) girilmelidir. Eğer bilinmiyorsa kameranın üretici değerlerinin sabit yansıma değerleri kullanılmalı.




Şekil 5.52 5. Çalışma için (RGB-NIR-Re) fotoğrafların yazılıma eklenmesi.

Bu çalışma için yansıma değerleri çizelge 5.19’da verilmiştir. Yansıma değerlerinin girilmesi Şekil 5.53’da gösterilmiştir.


Çizelge 5.19 5. Çalışmada kullanılan MicaSense RedEdge-M kamera yansıma değerleri

Bant	Reflactance factor value
R	0.510
G	0.612
B	0.509
Re	0.408
NIR	0.372



Şekil 5.53 MicaSense RedEdge-M kamera yansıma değerlerinin tanıtılması.

İHA ile çekilen görüntüler, Pix4D yazılımı aracılığıyla fotogrametrik olarak dengelemesi yapılmıştır. Üretilen ortofotoların yer örneklem aralığı (GSD) 6.52 cm çözünürlüğe sahiptir. Çalışma alanına ait ortofoto ve DSM Şekil 5.54’de gösterilmiştir. Pix4D yazılımında fotogrametrik değerlendirme yapıldıktan sonra Omega, Phi, Kappa değerleri sırasıyla 0.239 - 0.213 - 0.087 elde edilmiştir.



Şekil 5.54 5. Çalışma alanına ait her bant için ortofoto (sol) ve DSM (sağ).


5.5.3 Nesne Tabanlı Sınıflandırma

Bu çalışmada uygulanan nesne tabanlı sınıflandırma çalışması; segmentasyon, sınıflandırma ve doğruluk analizlerinde oluşmaktadır. Segmentasyon aşamasında ilk çalışmada detaylı anlatılan ölçek, şekil ve bütünlük parametrelerinin belirlenmesi işlemleri aynı şekilde yapılmıştır.

Segmentasyon için çoklu çözünürlüklü segmentasyon seçilmiştir. Çeşitli denemelerden sonra çizelge 5.20’de verilen değerler seçilmiştir. Segmentasyon görüntüsü Şekil 5.55’de gösterilmiştir.

Çizelge 5.20 5. Çalışma (RGB-NIR-Re) için seçilen segmentasyon değerleri


Parametre	Değer
Ölçek	100
Şekil	0.2
Bütünlük	0.8



Şekil 5.55 5. Çalışma alanı için (RGB-NIR-Re) segmentasyon.


Segmentasyon işleminden sonra tüm alan detaylı bir şekilde incelenmiş ve inceleme sonucu çeşitli sebeplerle bütünlüğü bozulmuş veya başka nesneye ait segmentle karışmış olan bazı nesneler yazılımın elle nesne ayırma ve nesne birleştirme özellikleri kullanılarak düzeltilmiştir. Segmentasyon işleminden sonra sınıflandırma işlemine geçilmiştir. Bu aşamada çeşitli bant kombinasyonları oluşturmuş ve karşılık gelen aralıktaki nesneler gri renk tonunda elde edilen aralıktan istenen detaylar çıkartılmıştır. Bu çalışmada hem çizelge 5.1’deki hem de çizelge 5.6’daki bantlar ve denklem 5.19’deki bant kombinasyonu kullanılmıştır.

Çeşitli bant kombinasyonları belirlendikten sonra sınıflandırma işlemine geçilmiştir. Sınıflandırma, birleştirme ve şekil ve sınır düzeltme işlemleri Şekil 5.56’da gösterilmiştir.



Şekil 5.56 5. Çalışma için (RGB-NIR) sınıflandırma aşamaları.

Şekil 5.57’de sınıflandırma sonucu gösterilmiştir.



Şekil 5.57 5. Çalışma için (RGB-NIR) sınıflandırma aşamaları.

Sınıflandırma çalışması bittikten sonra doğruluk analizine geçilmiştir. Doğruluk analizi diğer çalışmalarda olduğu gibi hem eCognition yazılımında TTA örneklerine dayalı hata matrisi “(Error matrix based on TTA samples)” yöntemi ile hem de Mapinfo yazılımında noktaların konumu araştırılarak yapılmıştır.

İlk yöntem için toplam 59256 segment araştırılmıştır. Denklem 4.7’ye göre örneklem sayısı 245 belirlenmiştir. Doğruluk analizi sonucu çizelge 5.21 ve 5.22’de gösterilmiştir.

Çizelge 5.21 5. Çalışma için (RGB-NIR-Re) nesne-tabanlı sınıflandırma sonuçların doğruluk değerlendirmesi

Sınıf	Toplam Segment	Referans Segment Sayısı	Sınıflandırılmış Segment	Doğru Sınıflandırılmış Segment	Üretici Doğruluğu	Kullanıcı Doğruluğu
Road	26817	79	75	65	82.28	86.67
Building	2512	7	7	6	85.71	85.71
Green_area	32112	93	90	86	92.47	95.56
Ground	22771	66	58	53	80.30	91.38
Toplam	84212	245	229	212	86.53	92.58

Sınıflandırma neticesinde farklı sınıflar için; Üretici Doğrulukları %80 ile %92 arasında, Kullanıcı Doğruluğu %85 ile %95 arasında değişim göstermiştir. Üretici ve kullanıcı doğruluğu sırasıyla %82.28 ile %85.67 olarak bulunmuştur.

Çizelge 5.22 5. Çalışma (RGB-NIR-re) için nesne-tabanlı sınıflandırma sonuçların Kappa İstatistik tablosu

Sınıf	Kapa İstatistiği
Road	0.8715
Building	0.8314
Green_area	0.9314
Ground	0.8614
Genel Kapa Değeri: 0.9004	

Sınıflandırma neticesinde genel kapa değeri (Kappa index of agreement (KIA)) seviyesi %90 olarak tespit edilmiştir. eCognition Developer yazılımında doğruluk analizi yapıldıktan sonra MapInfo yazılımında doğruluk analizi yapılmıştır. Karşılaştırmak için ilk olarak örneklem seçilmiştir. Örneklem uzayı yanı toplam kütle (N) “feature to polygon” işleminde oluşturulan tüm alandaki polygonlar seçilmiştir. Bu Çalışma için hedef kitledeki birey sayısı (ana kütle sayısı) yani “N” 5715373 oluşmuştur. Denklem 4.7’ye göre örneklem sayısı “n” 1453 hesaplanmıştır. Karşılaştırma verisi olarak daha önce klasik metotlarla üretilen vektör harita kullanılmıştır. Vektör harita referans kabul edilmiştir. Çalışma alanına rastgele nokta (random point) ile örneklem noktaları denenmiştir.

Çizelge 5.23 5.Çalışma için (RGB-NIR-Re) nesne tabanlı sınıflandırma doğruluk sonuçları

Tahmin				Tahmin			
	P	N		P	N	Toplam	
Gerçekle	P	TP	FN	P	72	617	
	N	FP	TN	N	107	836	
Toplam				652	801		

Denklem 4.8-4.9-4.10-4.11-4.12’ye göre gerekli hesaplamalar yapılmıştır. Çizelge 5.23’e göre Doğruluk, Hassasiyet, Duyarlılık, *F1Puanı* ve Özgünlük sırasıyla; 0.8768 – 0.8359 – 0.8833–0.8589–0.8720 hesaplanmıştır.

6. BULGULAR

Çalışma kapsamında 4 farklı alanda 5 farklı uygulama gerçekleştirilmiştir. İki çalışmada, farklı İHA'lerden elde edilmiş RGB görüntüler kullanılmıştır. Diğer çalışmalarda ise RG-Nır bantlı, RG-Nır-Re bantlı ve RGB-Nır-Re bantlı görüntüler kullanılmıştır. Bütün çalışmalarda nesne tabanlı sınıflandırma yöntemi ile yol detaylarının ve diğer detayların tespiti gerçekleştirilmiştir. Yolların tespiti için öncelikle kural setleri geliştirilerek kırmızı çatılı ve beyaz çatılı binalar çıkarılmıştır. Yeşil alanların olduğu kısımlarda ise green bantı ve NDVI indeksi kullanılmıştır. Yol olmayan çoğu detaylar maskelendikten sonra her çalışma özelinde yol detayları için kural setleri oluşturulmuştur. Oluşturulan bu kural setleri diğer çalışma alanlarında uygulanmıştır fakat istenilen sonuçlar alınamamıştır. Bundan dolayı her çalışma alanı için ayrı kural setleri oluşturulmuştur. Aynı kural setinin farklı çalışmalarda istenilen düzeyde çalışmamasının sebebi; İHA verilerinin elde edilme zamanı, havanın bulutlu veya bulutsuz (açık veya kapalı) olması, alanda bulunan insan yapımı nesnelerin farklılık göstermesi gibi nedenler ile alakalı olduğu düşünülmektedir. Her çalışma alanına uygulanan kural setleri ile yol detayları tespit edilirken yol olmayan nesnelerin yol olarak tespit edildiği görülmüştür. Özellikle yol kenarında bulunan kaldırım ile toprak yolların çok fazla karıştığı gözlemlenmiştir. Her çalışma alanında DSM ve DTM kullanılarak oluşturulan NDSM ile 2 metreden büyük olan nesneler diğer sınıflara atılmıştır. NDSM kuralının uygulanmadığı çalışmalarda özellikle üst geçitler ile yol detayları ile aynı özellikler gösteren binaların yol ile karıştığı gözlemlenmiştir. Benzer şekilde NDSM kural setinin 2 metre altında kalan taşıtlardan özellikle gri renkte olanların yol sınıfına karıştığı görülmüştür. Bu durum ise en yakın komşuluk değerinin 0.9'dan büyük olanların yol sınıfına atanması kuralı ile çözümlenmiştir. Bunlara ek olarak toprak yolların birçoğu yol sınıfı ile karışmıştır. Bu durumun çoğunluğu DDVI indeksi başta olmak üzere çeşitli kural setleri ile çözülmeye çalışılmıştır.

Her bir çalışma alanının özellikleri ve verileri birbirinden farklıdır. Bu nedenle hesaplanan üretici ve kullanıcı doğrulukları birbirinden farklılık göstermektedir. Tez çalışması kapsamında uygulanan 5 çalışmanın üretici ve kullanıcı doğrulukları ile doğruluk ve duyarlılık analizleri çizelge 6.1'de gösterilmiştir.

Çizelge 6.1 Genel doğruluk tablosu

Çalışma Adı	eCognition		MapInfo	
	Üretici Doğruluğu	Kullanıcı Doğruluğu	Doğruluk	Duyarlılık
Çalışma 1 Afyon RGB	77.2152	85.9155	0.8192	0.8165
Çalışma 2 Afyon RG-NIR	80.4900	86.8400	0.8566	0.8268
Çalışma 3 İzmir RG-NIR-Re	83.3333	90.9091	0.8893	0.8926
Çalışma 4 Yozgat RGB	77.0833	86.0465	0.7520	0.8158
Çalışma 5 İsviçre (Test alanı) RGB-NIR-Re	82.2785	86.6667	0.8768	0.8359

İki farklı yazılımda gerçekleştirilen doğruluk analizi ve çizelge 6.1'deki sonuçlar değerlendirilecek olunursa, üretici doğruluğu %83.3333 ile 3. çalışma alanına ait RG-NIR-RE bantlı uçuş verilerinden elde edilmiştir. MapInfo yazılımında yapılan doğruluk analizi sonucuna göre de 3. Çalışma 88.93 değeri ile en yüksek doğruluğa sahiptir. Özellikle RGB bantlara sahip 1. ve 4. çalışmalar düşük doğruluk göstermişlerdir. NIR ve Re bantlarının doğruluğa önemli bir etkisi olduğu görülmüştür. Yol detayların daha çok zemin ve kaldırımlar ile karıştığı görülmektedir. Ek olarak bazı yerlerde yeşil alanlar ile karışmaktadır. Yeşil alanlar ile karışan yol detayları bitki indeksleri ile kolay bir şekilde ayırt edilebilmektedir. 3. Çalışma alanı daha çok yeşil alanlardan oluştuğu için bu durum doğruluğun yüksek çıkmasına önemli bir etki oluşturmaktadır. RGB görüntülerin kullanıldığı alanlarda sık yerleşim yerleri bulunduğu için diğer nesneler ile yol detayları oldukça fazla karışmıştır. Bu durum NIR ve Re bantların bulunduğu çalışma alanlarında kullanılan kural setlerinden daha fazla kural yazılması gerektiğini doğurmuştur.

7. TARTIŞMA ve SONUÇ

Son zamanlarda, yüksek çözünürlüklü görüntüler üzerindeki spektral özellikleri ve bunların renk, doku ve şekil gibi objektif özelliklerini dikkate alan nesne tabanlı sınıflandırma tekniklerinin kullanılması görüntülerinin tematik sınıflandırılmasında daha yaygın hale gelmiştir (Kalkan ve Maktav 2010; Sabuncu ve Sunar 2017)

Nesneye dayalı sınıflandırma tekniği, görüntüleri segmentasyon aşamasında benzer spektral özelliklerle kümeler oluşturması ve daha sonra segmentlere ayrılan görüntünün farklı sınıflara ait örnek nesnelerin seçimi ve son olarak sınıflandırma algoritmalarını kullanarak sınıflandırmanın tamamlanması işlemlerinden oluşmaktadır.

Segmentasyon, nesne yönelimli sınıflandırmada en önemli süreçtir. Nesneleri bölerek görüntünün bölümlere ayrılmasını sağlayan parametreler genellikle kullanıcı tarafından belirlenmelidir. Ancak bu karar her çalışma alanı için özel olmalıdır. Segmentasyon sonucunda oluşturulan segmentler, sınıflandırma sonucunun doğruluğunu doğrudan etkiler. Segmentlerin yanlış oluşturulması da sınıflandırılan görüntüyü olumsuz etkilemektedir. Bu nedenle, bu sürecin bir sonucu olarak en ideal segmentler oluşturulmalıdır.

Nesne tabanlı sınıflandırma işleminin ikinci adımını segmentlerin sınıflara atanması işlemi oluşturmaktadır. Oluşturulan segmentleri sınıflara atamak için, görüntüleri literatürde kullanılan bant kombinasyonları ile gri renkli görüntülere dönüştürülmesi gerekmektedir. Bu işlemin amacı, görüntüdeki özellikler kullanılarak tespit edilmesi gereken sınıfın özelliklerini ortaya çıkarmaktır. Literatürde mevcut olan bant kombinasyonları, segmentasyon işlemi sonucunda ortofoto görüntüden elde edilen segmentleri sınıflara atamak için kullanılmıştır. Çeşitli bant kombinasyonları denendikten sonra birçok segmentin doğru sınıfa atandığı görülmüştür. Fakat yanlış sınıfa atanan segmentler sınıflandırmanın doğruluğunu düşürmektedir. Özellikle RGB bantların kullanıldığı görüntülerde toprak sınıfı yol sınıfı ile daha fazla karışmıştır. Bunun temel nedeni olarak ortofoto görüntüsü sınıflandırmasında sadece üç bant kullanılması gösterilebilir. RGB bantlara ek olarak NIR ve Re bantların kullanılması sınıflandırmanın doğruluğunu arttırdığı görülmüştür. Çizelge 6.1 incelendiğinde hem eCognition yazılımında hem MapInfo yazılımında yapılan doğruluk analizine göre en yüksek doğruluk

RG-NIR-re bantlarının kullanıldığı görüntülerden elde edilmiştir. Üretici doğruluğu, kullanıcı doğruluğu, doğruluk ve duyarlılık sırasıyla 83.3333-90.9091-0.8893-0.8926 bulunmuştur.

Yapılan beş farklı uygulama sonucunda, nesne tabanlı yaklaşım metodu ile ana yollarda başarılı, tali yollarda orta derecede başarılı iken toprak yollarda başarısız olunmuştur. Yolların; seyrek yapılaşmanın az, yeşil alanların bol olduğu alanlarda yüksek doğrulukta tespit edildiği görülmüştür. Orta kalitede başarılı olunan tali yolların tespitinde, yapılaşmanın düzgün ve fazla olduğu alanlarda düzensiz yapılaşmaya göre daha başarılı olduğu görülmüştür. Ağaçların az olduğu alanlarda ana yolların ve düzgün yapılaşmış kentsel alanlarda tali yolların nesne tabanlı yaklaşım ile etkili bir şekilde çıkarılabildiği, yapılaşmanın bozulduğu ve ağaçların yolları kapattığı alanlarda nesne tabanlı yaklaşımın başarısız olduğu tespit edilmiştir. Buna ek olarak toprak yollar ile ham arazi örtüsünün aynı spektral yansıma değerlerine sahip olması, toprak yollar üzerinde bulunan otsu nesnelerin bulunması; toprak yolların nesne yönelimli bir yaklaşımla çıkarılmasında olumsuz etkiye sebep olduğu gözlemlenmiştir. Ortofoto görüntüsündeki asfalt yol ile aynı spektral yansıma değerleri içeren özellikle beton çatılı binalar hem segmentasyonun kalitesini hem de sınıflandırmayı olumsuz etkilemektedir. Bu problemler uygun özellik ve farklı kurallar kullanılarak giderilmeye çalışılmıştır.

Uzun yıllardır kullanılan piksel tabanlı yaklaşımın yerini alan nesne tabanlı yaklaşım algoritması kullanarak segmentasyon işlemi yapılması neticesinde nesnelerin sınıflandırılması büyük ölçüde başarılı bir şekilde yapılmaktadır. Nesne tabanlı sınıflandırma yazılımı olan Definiens eCognition ile yapılan sınıflandırma süreci daha hızlı ve güncellenebilir bir şekilde gerçekleşmektedir. Ayrıca yapılan yanlışlar ya da hatalı sınıf atamaları hızlı bir şekilde düzeltilebilir sınıflandırma sonucu vektör formata çevrilerek coğrafi bilgi sistemleri ile entegre edilebilir. Nesne tabanlı yöntemle yüksek çözünürlüklü görüntülerden elde edilen vektör veriler, harita üretim uygulamalarında kullanım amacına göre referans veri olarak kullanılabilir. Örneğin bu verileri; yasadışı, çarpık ve hızlı yapılaşmanın kontrolü için bir referans haritası olarak kullanmak mümkündür.

8. KAYNAKLAR

- Aggarwal N, Srivastava M, Dutta M, 2016, Classification of objects from High Resolution Remote Sensing Images using eCognition, International Journal of Engineering Trends and Technology (IJETT), 38, 12-15.
- Atak H, 2018, İnsansız Hava Araçları Kullanarak Ortofoto Harita Üretimi ve Doğruluk Analizleri, Yüksek Lisans Tezi, 67s, Gebze Teknik Üniversitesi, Harita Mühendisliği Anabilim Dalı, Jeodezi ve Coğrafi Bilgi Teknolojileri Programı.
- Ayhan E, Karşlı F, Tunç, A, 2003, Uzaktan Algılanmış Görüntülerde Sınıflandırma ve Analiz, Harita Genel Komutanlığı Harita Dergisi, 130, 32-46.
- Baatz M, Schape A. (2000). Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation. Proceedings of Angewandte Geographische Informationsverarbeitung XII, 12-23.
- Baatz M, Benz U, Dehghani S, Heynen M, Höltje, A, Hofmann, vd.2004, eCognition Professional: User Guide 5, Definiens-Imaging, Munich.
- Bacher U, Mayer H, 2005, Automatic Road Extraction from Multispectral High Resolution Satellite Images, IAPRS, XXXVI, Vienna, Austria, August 29-30, 2005
- Bannari A, Asalhi H, Teillet P M, 2002, Transformed difference vegetation index (TDVI) for vegetation cover mapping, Geoscience and Remote Sensing Symposium, 24-28 June 2002, Toronto, 5.
- Batur E, Maktav D, 2016, Uzaktan Algılama ve CBS Entegrasyonu ile Taşkın Alanlarının Belirlenmesi: Meriç Nehri Örneği, Havacılık ve Uzay Teknolojileri Dergisi, 5, 47-54.
- Becker C, H'ani N, Rosinskaya E, d'Angelo E, Strecha C, 2017, Classification of Aerial Photogrammetric 3d Point Clouds, arXiv:1705.08374v1.
- Benz U C, Hofmann P, Willhauck G, Lingenfelder I, Heynen M, 2004, Multi-resolution object-oriented fuzzy analysis of remote sensing data for GIS- ready information,

ISPRS Journal of Photogrammetry and Remote Sensing, 58, 239-258.

Bergsjö J, 2014, Object based change detection in urban area using KTH-SEG, Bachelor Thesis, Kth Royal Institute Of Technology, Stockholm.

Bigras C, 1997, Kite aerial photography of the Axel Heiberg Island fossil forest, in: American Society of Photogrammetry and Remote Sensing. First North American Symposium on Small Format Aerial Photography, 147- 153.

Bilgilioglu B B, 2015, Uzaktan Algılanmış Görüntülerden Faydalınarak Nesne Tabanlı Sınıflandırma Yöntemi ile Kent Merkezlerindeki Detayların Çıkarımı ve Yorumlanması, Yüksek Lisans Tezi, 79s, Fen Bilimleri Enstitüsü, Aksaray Üniversitesi, Aksaray.

Bulatov D, H'aufel G, Pohl M, 2016, Vectorization of Road Data Extracted from Aerial and UAV Imagery, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B3, London.

Bulatov D, Warnke S, 2017, Extraction of Road Pixels from Airborne Image and Elevation Data: Focusing on Feature Selection, International Conference on Digital Image Computing: Techniques and Applications (DICTA).

Burnett C, Blaschke T, 2003, A Multi-Scale Segmentation / Object Relationship Modelling Methodology for Landscape Analysis, Ecological Modelling, 168, 233-249.

Burtch R, 2006, History of Photogrammetry. The Center for Photogrammetry Training Surveying Engineering Department, Ferris State University, Michigan, ABD.

Campbell J B, 1996, Introduction to remote sensing, Guilford Press, New York, USA.

Cramer M, 2013, On The Use of RPAS in National Mapping – The EuroSDR Point of View, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-1/W2.

Crippen R E, 1990, Calculating the vegetation index faster, Remote Sensing of

Environment, 34, 71-73.

Cryderman C, Shufletoski A, 2015, Evaluation of UAV Photogrammetric Accuracy for Mapping and Earthworks Computations, GEOMATICA, 68, 309-17.

Çelik R, 2006, Yüksek Çözünürlüklü Uydu Görüntülerinden Tam Otomatik Yol Bilgisi Çıkartma ve CBS Tabanlı Analizi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, 80s, Zonguldak.

Çölkesen İ, Sesli F A, 2007, Kıyı Çizgisinde Meydana Gelen Zamansal Değişimlerin Bilgi Teknolojileri ile Belirlenmesi: Trabzon Örneği, TMMOB Harita ve Kadastro Mühendisleri Odası Ulusal Coğrafi Bilgi Sistemleri Kongresi, KTÜ, Trabzon.

Çömert R, Avdan U, Şenkal E, 2012, İnsansız Hava Araçlarının Kullanım Alanları ve Gelecekteki Beklentiler. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Zonguldak.

Çömert R, Matcı D K, Avdan U, 2017, Yıkılmış Binaların Nesne Tabanlı Sınıflandırma ile İnsansız Hava Aracı Verilerinden Tespit Edilmesi, 4. Uluslararası Deprem Mühendisliği ve Sismoloji Konferansı, Eskişehir.

Dawson, T P, Curran P J, 1998, A new technique for interpolating the reflectance red edge position, International Journal of Remote Sensing, 11, 2133–2139.

Definiens, 2012, Definiens Developer XD 2.0.4. Reference Book, Definiens AG München, Germany.

Dorninger P, Pfeifer N, 2008, A Comprehensive Automated 3D Approach for Building Extraction, Reconstruction, and Regularization from Airborne Laser Scanning Point Clouds, Vienna, 8, 11, 7323-7343.

Draeyer B, Strecha, C, 2014, White paper: How accurate are UAV surveying methods? Pix4D White paper.

Eisenbeiss H L, Zhang, 2006, Comparison of Dsms Generated From Mini UAV Imagery

and Terrestrial Laser Scanner in a Cultural Heritage Application. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVI-5: 9096.

Eisenbeiss H, 2009, UAV Photogrammetry, PhD Thesis, University of Technology Dresden, ETH Zurich, Switzerland, 203 pp.

Eisfelder C, Kraus T, 2009, Towards automated forest-type mapping - a service within GSE Forest Monitoring based on SPOT-5 and IKONOS data. International Journal of Remote Sensing, 30, 5015-5038

Elberink O, 2010, Acquisition of 3D Topography: Automated 3D Road and Building Reconstruction Using Airborne Laser Scanner Data and Topographic Maps. Ph.D. Thesis, University of Twente, Faculty of Geo-Information and Earth Observation ITC, Enschede, The Netherlands.

Everaerts J, 2008, The Use of Unmanned Aerial Vehicles (IHAS) for Remote Sensing and Mapping, In: The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, ISPRS Congress, XXXVII, 1187-1192, Beijing.

Fırat O, Erdoğan M, 2015, Nesne Tabanlı Sınıflandırma Tekniği ile Multispektral Hava Fotoğraflarından Otomatik Bina Çıkarımı, Tufuab VIII. Teknik Sempozyumu / Konya.

Förstner W, Gülch E, 1987, A Fast Operator for Detection and Precise Location of Distinct Points, Corners and Centres of Circular Features. ISPRS Intercommission Workshop, Interlaken, 149-155.

Geçen R, Sarp G, 2007, Yüksek ve Düşük Çözünürlüklü Uydu Görüntülerinden Yolların Tayini, TMMOB Harita ve Kadastro Mühendisleri Odası Ulusal Coğrafi Bilgi Sistemleri Kongresi, KTÜ, Trabzon

Gitelson A Y, Kaufman, Merzylak M, 1996, Use of a Green Channel in Remote Sensing of Global Vegetation from EOS-MODIS, Remote Sensing of Environment, 58, 289-298.

- Hunt E, Raymond Jr, Doraiswamy P C, McMurtrey J E, Daughtry C ST, Perry E, 2013, A visible band index for remote sensing leaf chlorophyll content at the canopy scale, Publications from USDA-ARS / UNL Faculty, 1156.
- Hoffman R, Jain, A K, 1987, Segmentation and Classification of Range Images, IEEE Trans, Pattern Anal, Machine Intell, 9, 608–620.
- 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.
- 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, edited by Jürgens, Carsten (Regensburg).
- Kahveci M, Can N, 2017, İnsansız Hava Araçları: Tarihçesi, Tanımı, Dünyada ve Türkiye'deki Yasal Durumu. Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi, 5, 511-535.
- Kalkan K, Maktav D, 2010, Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (IKONOS Örneği), II. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, 11 – 13, Gebze – KOCAELİ.
- Karakış S, Marangoz A M, Büyüksalih G, 2005, QuickBird Pan-Sharpned Görüntüsü Üzerinden Otomatik Detay Çıkarımı ve Coğrafi Bilgi Sistemlerine Uygunluğunun Analizi, 10.Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- Karkınlı A, Kesikoğlu A, Kesikoğlu M H, 201, İnsansız Hava Araçları ile Sayısal Arazi Modeli Üretimi, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VIII. Sempozyumu, Konya.
- Karslı F, Fidan M H, Dihkan M, 2009, Kızılötesi Hava Fotoğraflarından Bina Detaylarının Çıkarılması. MMOB Harita ve Kadastro Mühendisleri Odası 12.

Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.

Kavzoglu T, Yildiz M, 2014, Parameter-Based Performance Analysis of Object-Based Image Analysis Using Aerial and Quikbird-2 Images. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, II-7, 31-37.

Kavzoglu T, Tonbul H, 2017, A comparative study of segmentation quality for multi-resolution segmentation and watershed transform, 8th International Conference on Recent Advances in Space Technologies (RAST), 113-117.

Kılınçoğlu D B, 2016, Farklı İnsansız Hava Araçları ile Elde Edilen Görüntülerin Otomatik Fotogrametrik Yöntemlerle Değerlendirilmesi ve Doğruluk Analizi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul üniversitesi, İstanbul.

Konecny G, 1985, The International Society for Photogrammetry and Remote Sensing - 75 Years Old, or 75 Years Young, Keynote Address, Photogrammetric Engineering and Remote Sensing, 51, 919-933.

Laliberte A S, Goforth M A, 2011, Multispectral Remote Sensing From Unmanned Aircraft: Image Processing Workflows and Applications For Rangeland Environments. Remote Sensing 3, 2529 - 2551.

Maktav D, Siegmund A, Jurgens C, Naumann S, Sunar F, Eşbah H, vd. 2010, Kentsel Gelişim için Potansiyel Alanların Uzaktan Algılama ve CBS ile Belirlenmesi ve Değerlemesi, III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Kocaeli.

Mao W, Wang Y, Wang Y, 2003, Real-time detection of between-row weeds using machine vision, In 2003 ASAE Annual Meeting (p. 1). American Society of Agricultural and Biological Engineers.

Marangoz A M, 2002, Sayısal kameralarla tarihsel yapıların rölövelerinin çıkarılması olanakları, Yayınlanmamış yüksek lisans tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Marangoz A M, Oruç M, 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, Istanbul, Turkey.

Marangoz A M, Karakış S, Oruç M, Büyüksalih G, 2005, Nesne-Tabanlı Görüntü Analizi ve Ikonos Pan-Sharpended Görüntüsünü Kullanarak Yol ve Binaların Çıkarımı, TMMOB Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.

Marangoz A M, 2009, Uydu Görüntülerinden Kentsel Ayrıntıların Nesne-Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi ve CBS Ortamında Bütünleştirilmesi, Doktora tezi, YTÜ Fen Bilimleri Enstitüsü, İstanbul.

Mcfeeters S K, 1996, The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. International Journal of Remote Sensing, 17, 1425-1432.

Motohka T, Nasahara K N, Oguma H, Tsuchida S, 2010, Applicability of green-red vegetation index for remote sensing of vegetation phenology, Remote Sensing, 2, 2369-2387.

Navulur K, 2007, Multispectral Image Analysis Using the Object-Oriented Paradigm, CRC Press, Taylor & Francis Group, 33487-2742.

Nixon M, Aguado A, 2008, Feature Extraction & Image Processing, Second edition, Elsevier.

Oğuz A E, 2012, Uçak Üzeri Eş Zamanlı Konumlama ve Haritalama (Ezkh)'da Artırılmış Tutarlılık İçin Gözlenebilirlik Kısıtlı Kalman Filtreleri, Doktora Tezi.

Pankiw J R, 2013, The Use of Object-Based Classification of High Resolution Panchromatic Satellite Imagery for the Inventory of Shelterbelts in the Province of Saskatchewan, Doktora Tezi, Faculty of Graduate Studies and Research, University of Regina.

Peng X, Zhaoqin L, Jinkuan Y, Yongrong L, 2008, Applying Unmanned Airship To Rapid Detection Of Urban Building Changes, The International Archives of the

Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVII.

Richardson J, Weigand C, 1977, Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, p. 43.

Rottensteiner F, Baillard C, Sohn G, Gerke M, 2012, ISPRS Test Project on Urban Classification and 3D Building Reconstruction, ISPRS Commission III Photogrammetric Computer Vision and Image Analysis Working Group III/4 Complex Scene Analysis and 3D Reconstruction.

Rouse J W, Haas R H, Schell J A, Deering DW, 1974, Monitoring vegetation systems in the Great Plains with ERTS, In: S.C. Freden, E.P. Mercanti, and M. Becker (eds) *Third Earth Resources Technology Satellite. Volume I: Technical Presentations*, NASA SP-351, NASA, Washington, D.C., pp. 309-317.

Sabuncu A, Sunar F, 2017, Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: Van- Erciş Depremi Örneği, *Artvin Çoruh Üniversitesi Doğal Afetler Uygulama ve Araştırma Merkezi Doğal Afetler ve Çevre Dergisi*, 1, 1-8.

Sameen M I, Pradhan B, 2017, A Two-Stage Optimization Strategy for Fuzzy Object-Based Analysis Using Airborne Lidar and High-Resolution Orthophotos for Urban Road Extraction. *Hindawi Journal of Sensors*, 17p.

Shan, Charles K T, 2018, *Topographic Laser Ranging And Scanning, Principles and Processing*, CRC Press Publishe.

Shu Z, Sun K, Qiu K, Ding K, 2016, Pairwise-Svm for On-Board Urban Road LIDAR Classification, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B1.

Sithole G, 2005, Segmentation and classification of airborne laser scanner data. Ph.D. Thesis, University of Delft, Publications on Geodesy, The Netherlands.

Smith L C, 1997, Satellite Remote Sensing of River Inundation Area, Stage and Discharge: A review, *Hydrological Processes*, 11, 1427-1439.

- Sonnentag O, Hufkens K, Teshera-Sterne C, Young A M, Friedl M, Braswell B H, vd., 2012, Digital repeat photography for phenological research in forest ecosystems. *Agric. For. Meteorol.* 152, 159–177.
- Sunar F, 2011, Uzaktan Algılama. T.C. Anadolu Üniversitesi Yayını NO: 2320, 1. Baskı, Eskişehir, Eylül 2011.
- Tapan K S, Bölme M, Eker O, 2015, Görüntülerden Sınıflandırma Yöntemlerini Kullanarak Detayların Otomatik Olarak Belirlenmesi: Renkli Kızılötesi Hava Fotoğraflarından Ormanlık Alanlarda Yolların Belirlenmesi İçin Bir Sınıflandırma Uygulaması, TUFUAB VIII. Teknik Sempozyumu, Konya.
- Tekin A B, Fornale M, Turhan M, Maso M, 2014, Tarımda Teknolojik Evrim; İnsansız Hava Araçları, Ege Üniversitesi, Ziraat Fakültesi Tarım Makinaları ve Teknolojileri Mühendisliği Bölümü, İzmir.
- Torun A, 2017, İnsansız Hava Aracı (İHA) Sektörü ve İHA Fotogrametrisinin Ölçme Bağlamında Konumlandırılması, TMMOB Harita ve Kadastro Mühendisleri Odası 16. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- UAS PEngineering, 2012, Aspects of Accuracy in UAS Photogrammetry, White Paper Version.
- Ural S, Shana J, Romeroa M A, Tarkoa A, 2015, Road and Roadside Feature Extraction Using Imagery and Lidar Data for Transportation Operation, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W4.
- Uysal M, Toprak A S, Polat N, 2013, Afyon Gedik Ahmet Paşa (İmaret) Camisinin Fotogrametrik Yöntemle Üç Boyutlu Modellenmesi, Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Sempozyumu, Trabzon.
- Van B P, 1999, İHAs: and Overview, In: *Air & Space Europe*. I, 5, 43-47.
- Vosselman G, Sester M, Mayer H, 2004, Basic Computer Vision Techniques. In: *Manual of photogrammetry* ed. by J.C. McClone, E.M. Mikhail, J.S. Bethel, Fifth edition. American Society for Photogrammetry and Remote Sensing (ASPRS), 455-504,

Bethesda.

Wang R, Hu Y, Zhang X, 2005, Extraction of road networks using pan-sharpened multispectral and panchromatic quickbird images. *Geomatica*, 59.

Widyaningrum E, Lindenbergh R C, 2019, Skeleton-Based Automatic Road Network Extraction from an Orthophoto Colored Point Cloud, The 40th Asian onference on Remote Sensing (ACRS 2019), Daejeon, Korea.

Woebbecke, D M, Meyer G E, Von Bargen K, Mortensen D A, 1995, Color indices for weed identification under various soil, residue, and lighting conditions. *Trans. ASAE* 38, 259–269.

Xue J, Su B, 2017, Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, vol. 2017, Article ID 1353691, 17p.

Yastıklı N, Bayraktar H, 2014, Yoğun Görüntü Eşleme Algoritmaları ile Yüksek Çözünürlüklü Sayısal Yüzey Modeli Üretimi. 5. Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2014), İstanbul.

Yıldız M, 2012, Görüntü Segmentasyon Metotlarının Sınıflandırma Performansı Üzerine Etkilerinin Araştırılması, Yüksek Lisan Tezi, Fen Bilimleri Enstitüsü, 81s, Gebze.

İnternet Kaynakları

1- <https://www.dji.com/phantom-3-pro/info>, 01.05.2020

2- <http://www.paksoytekNIK.com.tr/images/PAKSOY-TOPCON/IHA/sensefly>, 01.05.2020

3- <http://www.paksoytekNIK.com.tr/images/PAKSOY-TOPCON/IHA>, 01.05.2020

4- http://www.paksoytekNIK.com.tr/images/paksoy-topcon/ihaparrot_bluegrass, 01.05.2020

5- <https://www.mapir.camera/collections/survey3>, 01.05.2020

ÖZGEÇMİŞ

Adı Soyadı : Abdurrahman Yasin Yiğit
Doğum Yeri ve Tarihi : Ermenek / 04.04.1993
Yabancı Dili : İngilizce
İletişim (Telefon/e-posta) : abdurahmanyasinyigit@gmail.com

Eğitim Durumu (Kurum ve Yıl)

Lise : Antalya Çağlayan Anadolu Lisesi, (2007-2011)
Lisans : Selçuk Üniversitesi, Harita Mühendisliği Bölümü, (20014-2017)
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalı, (2017-2020)

Çalıştığı Kurum/Kurumlar ve Yıl : İlkim Harita İnş. Gayrimenkul Değ. Ltd. Şti
22.07.2019-09.12.2019

Mersin Üniversitesi Harita Mühendisliği
28.01.2020- Devam Ediyor.

Yayınları (SCI ve diğer) :

Ulvi A, Yiğit A, 2020, 3D Modelling of Kayseri Tekgoz Bridge. Mersin Photogrammetry Journal, 2, 29-32.

Yiğit A, Uysal M, 2020, Automatic Road Detection from Orthophoto Images. Mersin Photogrammetry Journal, 2, 10-17.

Yiğit A, Kaya Y, 2020, Sentinel-2A Uydu Verileri Kullanılarak Sel Alanlarının İncelenmesi: Düzce Örneği. Türkiye Uzaktan Algılama Dergisi, 2, 1-9.

Ulvi A, Yakar M, Yiğit A Y, Kaya, 2020, İHA ve Yersel Fotogrametrik Teknikler Kullanarak Aksaray Kızıl Kilisenin 3B Modelinin ve Nokta Bulutunun Elde Edilmesi. Geomatik Dergisi, 5, 22-30.

Yiğit A, Uysal M, 2019, Nesne Tabanlı Sınıflandırma ile Taşkın Alanlarının Analizi. Resilience, 3, 369-385.

Ulvi A, Varol F, Yiğit A Y, 2019, 3D Modelling and Digital Archiving of Cultural Heritage_the Example of Ismoil Somoniy Tomb in Uzbekistan, Journal of Tourism and Hospitality Management, 5.

Ulvi A, Yiğit A Y, Yakar M, 2019, Modeling of Historical Fountains by Using Close-Range Photogrammetric Techniques, Mersin Photogrammetry Journal, 1, 1-6.

Yiğit A Y, Uysal M, 2019, Nesne Tabanlı Sınıflandırma Yaklaşımı Kullanılarak Yolların Tespiti, Türkiye Fotogrametri Dergisi, 1, 17-24.

Ulvi A, Yiğit A Y, 2019, Kültürel Mirasın Dijital Dokümantasyonu: Taşkent Sultan Çeşmesinin Fotogrametrik Teknikler Kullanarak 3B Modelinin Yapılması, Türkiye Fotogrametri Dergisi, 1, 1-6.

Ulvi A, Yakar M, Yiğit A Y, Kaya Y, 2019, The Use of Photogrammetric Techniques in Documenting Cultural Heritage: The Example of Aksaray Selime Sultan Tomb. Universal Journal of Engineering Science, 7, 64 - 73.

Yakar M, Kabadayı A, Yiğit A Y, Çıkıkcı K, Kaya Y, Catin S S, 2016, Emir Saltuk Kümbeti Fotogrametrik Rölöve Çalışması ve 3 Boyutlu Modellenmesi, Geomatik Dergisi, 1, 14-18.

Bildiriler:

Ulvi A, Varol F, Yiğit A Y, 2019, 3D Modeling of Cultural Heritage: The Example of Muiy Mubarek Mosque in Uzbekistan (Hz.Osman's Mushafi), International Congress on Cultural Heritage and Tourism (ICCHT- 2019), Bishkek / KYRGYZSTAN (International)

Ulvi A, Yiğit A Y, Yakar M, 2019, Modeling of Historical Fountains by Using Close-Range Photogrammetric Techniques. CİSET - 2nd Cilicia International Symposium on Engineering and Technology, 10-12 October 2019, Mersin / TURKEY (International)

Yiğit A Y, Uysal M, 2019, Afet Yönetiminde Uzaktan Algılamanın Kullanımı, Uluslararası Afet ve Dirençlilik Kongresi, IDRC2019 / 26-28 Haziran 2019 / Eskişehir-Türkiye (International)

Ulvi A, Yakar M, Yiğit A Y, Kaya Y, 2019 Arkeolojik Alanların Dokümantasyonunun Yersel Lazer Tarama ve İHA Teknikleri ile Elde Edilmesi: Konya Yunuslar Örneği, TUFUAB X. Teknik Sempozyumu, 25-27 Nisan 2019, Aksaray-Türkiye (International)

Ulvi A, Varol F, Yiğit A Y, 2019, Kültürel Mirasın Dijital Dokümantasyonu: Taşkent Sultan Çeşmesinin Fotogrametrik Teknikler Kullanarak 3B Modelinin Yapılması. Uluslararası Taşeli Sempozyumu, Tam metinler kitabı sayfa: 542-554. 24 Ekim 2019-Konya / 25-26 Ekim 2019 – Alanya (International)

Yiğit A Y, Uysal M, 2019, İnsansız Hava Araçları ile Elde Edilen Verilerin Değerlendirilmesi ve Otomatik Yol Tespiti, TUFUAB X. Teknik Sempozyumu, 25-27 Nisan 2019, Aksaray-Türkiye, (International)

Yakar M, Ulvi A, Varol F, Yiğit A Y, Kaya Y, Kabadayı A, vd., 2018, Kültürel Miras Çalışmalarında Yersel Fotogrametri Yönteminin Uygulanması: Fetih Camii Örneği, II. International Congress on Cultural Heritage and Tourism, 3-5. Mayıs 2018, Taşkent-Özbekistan (International)

Yakar M, Ulvi A, Varol F, Yiğit A Y, Kaya Y, vd., 2018, 3D Model Production by Using UAV and Terrestrial Photogrammetric Techniques: The Example of Erzurum Three Kumbets, II. International Congress on Cultural Heritage and Tourism, 3-5 Mayıs 2018, Taşkent-Özbekistan (International)

Yakar M, Kaya Y, Çıkıkcı K, Catin S S, Yiğit A Y, Kabadayı A, cd., 2017, Cime Hatun Türbesi Rölöve Örneği, I. International Congress on Cultural Heritage and Tourism, 19-21 Mayıs 2017, Konya-Türkiye (International)

Yakar M, Yiğit A Y, Çıkıkcı K, Catin S S, Kaya Y, Kabadayı A, vd., 2017, Kasımpaşa Camii'si Rölöve Örneği, I. International Congress on Cultural Heritage and Tourism, 19-21 Mayıs 2017, Konya-Türkiye, (International)

Yakar M, Yiğit A Y, Kabadayı A., Çıkıkcı K, Catin S S, Kaya Y, vd., 2017. Erzurum Tarihi Konağın Yersel Fotogrametri Tekniği Kullanılarak Üç Boyutlu Modellenmesi ve Rölöve Örneği, I. International Congress on Cultural Heritage and Tourism, 19-21 Mayıs 2017, Konya-Türkiye (International)

Yakar M, Orhan O, Ulvi A, Yiğit A Y, Yüzer M M, 2015, Sahip Ata Külliyesi Rölöve Örneği, 15. Türkiye Harita Bilimsel ve Teknik Kurultayı, 25-28 Mart 2015, Ankara, (National)