

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MULTİSPEKTRAL UYDU GÖRÜNTÜLERİ KULLANARAK
NESNE TABANLI ARAZİ ÖRTÜSÜ DEĞİŞİM TESPİTİ

AYŞE ÇELİK
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ PROGRAMI

GEBZE
2022

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MULTİSPEKTRAL UYDU GÖRÜNTÜLERİ
KULLANARAK NESNE TABANLI ARAZİ
ÖRTÜSÜ DEĞİŞİM TESPİTİ

AYŞE ÇELİK
YÜKSEK LİSANS TEZİ
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ PROGRAMI

DANIŞMANI
DOÇ. DR. İSMAİL ÇÖLKESEN

GEBZE

2022

T.R.

GEBZE TECHNICAL UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

**OBJECT BASED LAND COVER CHANGE
DETECTION USING MULTISPECTRAL
SATELLITE IMAGES**

AYŞE ÇELİK

**A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE**

**DEPARTMENT OF GEOMATICS ENGINEERING
GEODESY AND GEOGRAPHIC INFORMATION TECHNOLOGIES PROGRAM**

THESIS SUPERVISOR

ASSOC. PROF. DR. İSMAİL ÇÖLKESEN

GEBZE

2022

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 23/06/2022 tarih ve 22/31 sayılı kararıyla oluşturulan jüri tarafından 26/09/2022 tarihinde tez savunma sınavı yapılan Ayşe ÇELİK'in tez çalışması Harita Mühendisliği Anabilim Dalı Jeodezi ve Coğrafi Bilgi Teknolojileri Programında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI)

:Doç. Dr. İsmail ÇÖLKESEN

ÜYE

:Prof. Dr. Arif Çağdaş AYDINOĞLU

ÜYE

:Dr. Öğrt. Üyesi Emrehan Kutluğ ŞAHİN

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Arazi örtüsü değişim tespiti ve süreci yaşadığımız dünyanın ekolojik modelinin belirlenmesinde uzaktan algılama verileri önemlidir. Değişim tespiti uygulamalarında segmentasyon ve sınıflandırma önemli bir işlem adımıdır. Bu çalışmada iki bölge incelenmiştir. Rize ve Yalova illerinde arazi örtüsü/arazi kullanımı değişim tespiti için çalışma yapılmıştır. İki çalışma bölgesindeki 2016 ve 2022 yılları için Sentinel-2A uydu görüntüleri kullanılmıştır. Çalışmada eCognition ve QGIS yazılımları kullanılmıştır. QGIS yazılımında ortalama kayma segmentasyonu yapılmış olup bunun sonucunda nesne tabanlı sınıflandırma yapılmıştır. eCognition yazılımında çoklu çözünürlüklü segmentasyon kullanılmış ve segment edilen görüntülere nesne tabanlı sınıflandırma yöntemi kullanılmıştır. Nesne tabanlı sınıflandırma destek vektör sonucu iki görüntü arasındaki fark alınarak değişiklik tespiti yapılmıştır. Üretilen sınıfların farklarına bakılarak hesaplanan yeni sınıflandırma haritası değişimin ne yönde olduğu gösterilmiştir. Daha sonra doğruluk değerlendirilmesi yapılmıştır. Bu çalışmada, iki bölgedeki her iki görüntünün ortalama kayma segmentasyonu sonucu destek vektör makineleri sınıflandırılması ile genel doğruluğu %84- %94 arasındadır. Çoklu çözünürlüklü segmentasyon sonucu en yakın komşuluk sınıflandırılması ile genel doğruluk %97-%99 arasındadır. 2016 ile 2022 yılları arasında nesne tabanlı sınıflandırma sonrası değişiklik tespiti, oluşturulan sınıflar arasında bazı bölgelerde düşüş, bazı bölgelerde yükseliş görülmüştür.

Anahtar Kelimeler: Uzaktan Algılama, Nesne Tabanlı Sınıflandırma, Segmentasyon, Değişim Tespiti.

SUMMARY

Remote sensing data is essential in determining the land cover change detection and the ecological model of our world. Segmentation and classification is an important process step in change detection applications. Two regions were examined in this study. A study was conducted to determine the land cover/land use change in the provinces of Rize and Yalova. Sentinel-2A satellite images were used for 2016 and 2022 in the two study regions. eCognition and QGIS software were used in the study. Mean shift segmentation was done in QGIS software, and as a result, object-based classification was made. Multi-resolution segmentation was used in eCognition software and object-based classification method was used for segmented images. Object-based classification support vector machines and the nearest neighbour classifier method are used. Change detection was made by taking the difference between the two images as a result of classification. The new classification map calculated by looking at the differences of the produced classes shows the direction of the change. Afterwards, an accuracy assessment was made. In this study, the overall accuracy of the support vector machine classification is between 84% and 94% due to the average shift segmentation of both images in two regions. With the nearest neighbor classification resulting from multi-resolution segmentation, the overall accuracy is between 97%-99%. Between 2016 and 2022, change detection after object-based classification, a decrease in some regions and an increase in some regions were observed among the classes created.

Key Words: Remote Sensing, Object Based Classification, Segmentation, Change Detection.

TEŞEKKÜR

Yüksek lisans eğitimim boyunca bana her türlü desteği gösteren, tez konusu belirlemede, yürütülmesinde, sonuçlandırılmasında ve diğer her aşamasında değerli bilgilerini ve tecrübelerini, hasta olduğumda manevi yardımlarını esirgemeyen değerli tez danışmanım Doç. Dr. İsmail ÇÖLKESEN'e teşekkürlerimi ve minnettarlığımı belirtmek isterim.

Tez çalışmalarım süresince bana maddi ve manevi desteklerini esirgemeyen çalışma arkadaşlarıma teşekkür ederim.

Her zaman eğitimin önemli olduğunu söyleyen, maddi ve manevi her türlü desteği sağlayan, her zaman ve her şekilde yanımda olan Ayla SOFU'ya, kardeşim Elmas SOFU'ya ve ablam Emine HATO'ya teşekkür ederim.

Tez sürecinde ve hayatımın iyi ve kötü gününde her durumda yanımda olan, bana her zaman destek olan değerli eşim, hayat arkadaşım Fatih ÇELİK'e, eğitim sürecinde hayatıma katılan en değerli varlıklarım olan çocuklarım Beren Sıla ve Bilge Duru'ya teşekkürlerimi ve şükranlarımı sunuyorum.

Sevgi ve saygılarımla.

İÇİNDEKİLER

	Sayfa
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xii
TABLolar DİZİNİ	xv
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	3
1.2. Metodoloji	3
1.3. Literatür Araştırması	5
2. UZAKTAN ALGILANMIŞ GÖRÜNTÜLERİN SINIFLANDIRILMASI	14
2.1. Görüntü Sınıflandırma	14
2.1.1. Piksel Tabanlı Sınıflandırma	15
2.1.2. Nesne Tabanlı Sınıflandırma	15
2.2. Görüntü Bölütleme (Segmentasyon)	16
3. UZAKTAN ALGILANMIŞ GÖRÜNTÜLER YARDIMIYLA DEĞİŞİM TESPİTİ	20
3.1. Görüntülerin Cebirsel Farklarıyla Değişim Analizi	20
3.2. Görüntülerin Dönüşüm Yöntemleriyle Değişim Tespiti	21
3.3. Görüntülerin Görsel Analiziyle Değişim Tespiti	22
3.4. Görüntülerin Sınıflandırılmasıyla Değişim Tespiti	22
3.4.1. Piksel Tabanlı Sınıflandırma Değişim Tespiti	23
3.4.2. Nesne Tabanlı Sınıflandırma Değişim Tespiti	30
4. UYGULAMA ve SONUÇLAR	33
4.1. Uygulama Alanı ve Veri	33
4.2. Segmentasyon	34

4.2.1. Ortalama Kaydırma (Mean-Shift) Segmentasyonu	35
4.2.2. Çoklu Çözünürlüklü (Multi-Resolution) Segmentasyonu	67
4.3. Değişim Tespiti Analizi	102
5. BULGULAR ve TARTIŞMA	111
5.1. Segmentasyon Algoritmaları Açısından Sonuçların Analizi	111
5.2. Değişim Tespiti Sonuçlarının Analizi	113
6. SONUÇLAR ve ÖNERİLER	116
 KAYNAKLAR	 118
ÖZGEÇMİŞ	126
EKLER	127



SİMGELER VE KISALTMALAR DİZİNİ

Simgeler ve Açıklamalar

Kısaltmalar

AKAÖ	: Arazi Kullanımı ve Arazi Örtüsü
UZ	: Uzaktan Algılama
km ²	: Kilometre kare
R	: Red, Kırmızı bant
G	: Green, Yeşil bant
B	: Blue, Mavi bant
NIR	: Near İnfrared, Yakın Kızılötesi Bant
m	: Metre
NDVI	: Normalized Difference Vegetation Index
EYK	: En Yakın Komşuluk
DVI	: Difference Vegetation-Index
PCI	: Precipitation Condition Index
SAFER	: Services and Applications For Emergency Response
DEM	: Dijital Yükseklik Modeli
ESP	: Estimation scale parameter
IFFI	: Inventario dei Fenomeni Franosi in Italia
PAI	: Piano Stralcio per l'Assetto Idrogeologico
PSI	: Persistent Scatterer Interferometry
ESA	: European Space Agency
GNSS	: Global Navigation Satellite Systems
CAD	: Computer Aided Design
CBS	: Coğrafi Bilgi Sistemleri
MSI	: MultiSpectral Instrument
Nm	: Nanometre
MRS	: Multi Resolution Segmentation
GLCM	: Gray-Level Co-Occurrence Matrix
SAVI	: Soil-Adjusted Vegetation Index
BSI	: Bare Soil Index

NDBI	: Normalized Difference Built-Up
GARI	: Green Atmospherically Resistant Vegetation Index
CVI	: Chlorophyll vegetation index
BDC	: Base Data Cube
CLC	: Corine Land Cover
OOB	: Out-Of-Bag
GEE	: Google Earth Engine
LULC	: Land Use/Land Cover
CVA	: Change Vector Analysis
PCA	: Principal Component Analysis
KT	: Tasselled Cap
EM	: Expectation-maximization
ANN	: Artificial Neural Network
GIS	: Geographical Information Systems
RVI	: Ratio Vegetation Index
PVI	: Perpendicular Vegetation Index
MSAVI	: Modified Soil-Adjusted Vegetation Index
CV	: Change Vector
PC	: Principal Component
SVM	: Support Vector Machine
DT	: Decision Tree
SMA	: Spectral Mixture Analysis
NDWI	: Normalized Difference Water Index

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
1.1: Metodolojinin iş akış şeması.	4
2.1: Nesne tabanlı sınıflandırma yönteminin iş akışı.	16
4.1: Çalışma alanı.	33
4.2: QGIS yazılımındaki iş akış şeması.	36
4.3: Rize ili 2016 yılı görüntüsü segmentasyon parametre seçim arayüzü.	37
4.4: Rize ili 2016 yılı ortalama kayma segmentasyon haritası.	38
4.5: Rize ili 2016 yılı segmentlerin referans nesnelerle örtüşme alanları.	39
4.6: Rize ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.	41
4.7: Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.	42
4.8: Rize ili 2022 yılı segmentasyon parametre seçim arayüzü.	45
4.9: Rize ili 2022 yılı ortalama kayma segmentasyon haritası.	46
4.10: Rize ili 2022 yılı segmentlerin referans nesnelerle örtüşme alanları.	47
4.11: Rize ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.	49
4.12: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.	50
4.13: Yalova ili 2016 yılı görüntüsü segmentasyon parametre seçim arayüzü.	53
4.14: Yalova ili 2016 yılı ortalama kayma segmentasyon haritası.	54
4.15: Yalova ili 2016 yılı segmentlerin referans nesnelerle örtüşme alanları.	55
4.16: Yalova ili 2016 yılı görüntüsünde segmentlere ait öznitelik bilgileri.	57
4.17: Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.	58
4.18: Yalova ili 2022 yılı görüntüsü segmentasyon parametre seçim arayüzü.	60
4.19: Yalova ili 2022 yılı ortalama kayma segmentasyon haritası.	61
4.20: Yalova ili 2022 yılı segmentlerin referans nesnelerle örtüşme alanları.	62
4.21: Yalova ili 2022 yılı görüntüsünde segmentlere ait öznitelik bilgileri.	64
4.22: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.	65

4.23: eCognition yazılımındaki iş akış şeması.	68
4.24: Rize ili 2016 yılı ESP-2 parametresi LV grafiği.	69
4.25: Rize ili 2016 yılı L1 değeri 78 olan ölçek parametresi için segmentasyon sonucu.	69
4.26: Rize ili 2016 yılı L2 ve L3 değeri 258 olan ölçek parametresi için segmentasyon sonucu.	70
4.27: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon parametreleri.	71
4.28: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon haritası.	72
4.29: Rize ili 2016 yılı segmentlerin referans nesnelerle olan örtüşme alanları.	73
4.30: Rize ili 2016 yılı görüntüsünde oluşan segmentlere ait öznelik bilgileri.	74
4.31: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.	75
4.32: Rize ili 2022 yılı ESP-2 parametresi LV grafiği.	77
4.33: Rize ili 2022 yılı için L1 değeri 76 olan ölçek parametresi için segmentasyon sonucu.	78
4.34: Rize ili 2022 yılı için L2 değeri 176 olan ölçek parametresi için segmentasyon sonucu.	78
4.35: Rize ili 2022 yılı için L3 değeri 276 olan ölçek parametresi için segmentasyon sonucu.	79
4.36: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon parametreleri.	80
4.37: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon haritası.	81
4.38: Rize ili 2022 yılı segmentlerin referans nesnelerle olan örtüşme alanları.	82
4.39: Rize ili 2022 yılı görüntüsünde oluşan segmentlere ait öznelik bilgileri.	83
4.40: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.	84
4.41: Yalova ili 2016 yılı ESP-2 parametresi LV grafiği.	86
4.42: Yalova ili 2016 yılı için L1 değeri 104 olan ölçek parametresi için segmentasyon sonucu.	87
4.43: Yalova ili 2016 yılı için L2 değeri 284 olan ölçek parametresi için segmentasyon sonucu.	87
4.44: Yalova ili 2016 yılı L3 değeri 684 olan ölçek parametresi için segmentasyon sonucu.	88
4.45: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon parametreleri.	89

4.46:	Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon haritaları.	89
4.47:	Yalova ili 2016 yılı segmentlerin referans nesnelerle örtüşme alanları.	90
4.48:	Yalova ili 2016 yılı görüntüsünde segmentlere ait öznitelik bilgileri.	91
4.49:	Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.	92
4.50:	Yalova ili 2022 yılı ESP-2 parametresi LV grafiği.	94
4.51:	Yalova ili 2022 yılı L1 değeri 99 olan ölçek parametresi için segmentasyon sonucu.	95
4.52:	Yalova ili 2022 yılı L2 değeri 249 olan ölçek parametresi için segmentasyon sonucu.	95
4.53:	Yalova ili 2022 yılı L3 değeri 549 olan ölçek parametresi için segmentasyon sonucu.	96
4.54:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon parametreleri.	97
4.55:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon haritası.	97
4.56:	Yalova ili 2022 yılı segmentlerin referans nesnelerle örtüşme alanları.	98
4.57:	Yalova ili 2022 yılı görüntüsünde segmentlere ait öznitelik bilgileri.	99
4.58:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.	100
4.59:	Rize ili ortalama kayma segmentasyonu değişim tespiti tematik haritası.	104
4.60:	Rize ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası.	106
4.61:	Yalova ili ortalama kayma segmentasyonu değişim tespiti tematik haritası.	108
4.62:	Yalova ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası.	110

TABLÖLER DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
4.1: Sentinel-2A görüntüsünün spektral bantları.	34
4.2: Rize ili 2016 yılı ortalama kayma segment bilgileri.	38
4.3: Rize ili 2016 yılı ortalama kayma segmentasyonu kalite metrikleri.	40
4.4: Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	43
4.5: Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	44
4.6: Rize ili 2022 yılı ortalama kayma segment bilgileri.	46
4.7: Rize ili 2022 yılı ortalama kayma segmentasyonu kalite metrikleri.	48
4.8: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	51
4.9: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	52
4.10: Yalova ili 2016 yılı ortalama kayma segment bilgileri.	54
4.11: Yalova ili 2016 yılı ortalama kayma segmentasyonu kalite metrikleri.	56
4.12: Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	59
4.13: Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	60
4.14: Yalova ili 2022 yılı ortalama kayma segment bilgileri.	62
4.15: Yalova ili 2022 yılı ortalama kayma segmentasyonu kalite metrikleri.	63
4.16: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	66
4.17: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	67
4.18: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon kalite metrikleri.	73
4.19: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	76

4.20:	Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	77
4.21:	Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon kalite metrikleri.	83
4.22:	Rize ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	85
4.23:	Rize ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	86
4.24:	Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri.	91
4.25:	Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	93
4.26:	Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	94
4.27:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri.	99
4.28:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.	101
4.29:	Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.	102
4.30:	Rize ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.	103
4.31:	Rize ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.	105
4.32:	Yalova ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.	107
4.33:	Yalova ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.	109
5.1:	Segmentasyon algoritmaları açısından sonuçların analizi.	112
5.2:	Rize ili değişim tespiti sonuçlarının analizi.	114
5.3:	Yalova ili değişim tespiti sonuçlarının analizi.	115

1.GİRİŞ

Dünya yüzeyindeki değişikliklerin tespiti ve incelenmesi konusunda çalışma alanının iki veya daha fazla görüntüsünün zamansal olarak karşılaştırılmasıyla ilgilidir [Singh, 1989]. Yaşadığımız dünyanın yüzey özelliklerini zamanında ve doğru olarak tespitinin yapılması, dünyadaki doğal kaynakları daha iyi kullanmak, insan ve çevre ile ilişkisini düzenlemek açısından önemli bir rol oynar. Uzaktan algılama teknolojileri yardımıyla belirlenebilen arazi örtüsü/ arazi kullanımı küresel çevresel değişikliklerin izlenmesinde kullanılan önemli bir araçtır [Singh, 1989].

Uzaktan algılama teknolojileri, yeryüzünün mevcut durumunun saptanması, planların ve haritaların yapılması, dünya yüzeyindeki değişimlerin saptanması çalışmalarına hızlı ve az maliyetli çözümler sağlamaktadır. Uzaktan algılama, arazi örtüsü ve kullanımın belirlenmesinde, orman türlerinin haritalanmasında, tarımsal ürün deseninin belirlenmesinde, sel taşkın alanlarının belirlenmesinde, deprem sonrası hasar tespiti ve arazi örtüsü ve arazi kullanımı değişikliklerinin saptanması gibi çalışmalarda da yaygın olarak kullanılmaktadır [Listner and Niemeyer, 2011]. Son yıllarda yüksek çözünürlüklü uydu görüntülerinin kullanımının artmasıyla sınıflandırma işleminde zorluklar ortaya çıkmaktadır [Ma et al., 2017]. Sınıflandırma işleminde piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yöntemleri en sık kullanılanlar arasındadır. Yüksek çözünürlüklü uydu görüntüleri ile piksel tabanlı sınıflandırmanın yerini nesne tabanlı sınıflandırma almıştır [Blaschke et al., 2014].

Uzaktan algılama metodu kullanılarak yapılan analizler neticesinde arazi örtüsünü temsil eden tematik haritalar üretilmektedir. Söz konusu haritaların üretilme süreçleri kullanılan veri setine, çalışma alanına ve yönteme göre zaman almaktadır. Uzaktan algılama neticesinde elde edilen sonuçlar bütünü o bölge hakkında fikir sahibi olmaya yaramaktadır. Uzaktan algılama sonucu ortaya çıkan uydu görüntüleri sayesinde vektörel veriler üzerinden sağlanan nesnelerin ayrıntılı tanımları öğrenilebilir, emek gereken bir işlem olarak ifade edilmektedir [Blaschke et al., 2014]. Uzaktan algılama bilimi her geçen gün daha da ilerlemektedir. Uzaktan algılama gözle görülemeyen birtakım ayrıntıları inceleme fırsatı sunmaktadır. Bununla birlikte teknolojinin gelişiminin hız kazanması uydu alıcılarının çözünürlüğü yüksek uydu görüntüleri oluşturmaya olanak sunmaktadır. Yüksek çözünürlüklü görüntüler sayesinde büyük ölçekli haritalar üretilmeye başlanmıştır [Holland et al., 2006].

Uzaktan algılama biliminde haritaların üretilmesi ve güncellenmesi evrelerinde doğru neticeler elde etmek amacıyla görüntülerin yorumlanması önem kazanmaktadır. Bununla birlikte ormanlık alanların belirlenmesi, kentsel yerleşim alanların belirlenmesi ve mera sahalarının belirlenmesi hususunda farklı metotlar geliştirilmiştir. Bu farklı metotlar sayesinde çeşitli alanlarda hava görüntülerinden ve uydu görüntülerinden yardım alınarak analizler yapılabilmektedir. Bu hedef doğrultusunda görüntü işleme metotlarıyla ilişkili tam otomatik ve yarı otomatik görüntü elde etme yöntemlerinin de kullanımı yaygınlaşmaktadır [Sandman and Lertzman, 2003].

Uzaktan algılama teknolojileri ile elde edilen görüntülerin analizinde çoğunlukla görüntü oluşturan piksellerin parlaklık değerleri dikkate alınmaktadır. Analizlerin neticesi düşük çözünürlüğe sahip uydu görüntülerinin piksel değerleri kapsamında ortaya çıkan analizlerin incelenmesi olarak ortaya çıkmaktadır. Uzaktan algılamanın gelişmesiyle birlikte yüksek çözünürlüklü uydular vasıtasıyla daha doğru sonuçlar elde edilmektedir. Buna karşın yapılan çalışmalarda uydu görüntüleri arazi ya da ormanlık alanlar üzerindeyse düşük çözünürlüklü uydu görüntülerinde de başarılı olunmaktadır. Büyük ölçekli haritaların yapım evrelerinde yüksek çözünürlüğe sahip uyduların kullanılması doğruluk payını daha fazla arttırmaktadır. Doğruluk payının artmasındaki asıl neden spektral varyans ile çözünürlüğün doğru orantıda olmasından kaynaklanmaktadır. Bununla birlikte spektral olarak ormanlık alanların karıştırılması sınıflandırma aşamasını zora sokmaktadır [Shaban and Dikshit, 2001].

Dünyanın nüfusu artmasıyla birlikte kentsel alanlarda yoğunlaşmıştır. Büyüyen şehirlere daha fazla yoğunluk ve yük bindirmektedir. Şehirler yeni yaşam alanları için ihtiyaç duyulan evler, işyerleri, kamusal alanlar ve sanayi alanlarıyla donatılmaktadır. Bu nedenle şehirler hem yatay büyümekte ve yükselmektedir. Bununla birlikte tarım arazileri ve ormanlık alanlar şehirleşmenin etkisinde azalmaktadır. Kentleşme biçiminde arazi örtüsü değişimiyle ifade edilmektedir [Kalnay and Cai, 2003]. Büyüyen kentler, gıda üretiminde sorunlara ve zorluklara neden olmaktadır. Tarımsal üretimin yapılmadığı kentlerde insanlar bu konularda ekonomik büyüme, nüfus artışı ve altyapının yetersizliğinin önüne geçmek için çalışmalar yapmaktadır [Antrop, 2004].

Arazi kullanımı ve arazi örtüsü (AKAÖ) değişikliği kentsel planlama, iklim ve tarımsal sürdürülebilirlik alanlarında bilgi ve önerileri sunarak katkıda bulunmaktadır [Dewen and Yamagucji, 2009]. Kentleşme ve tarımsal arazi kaybı gibi AKAÖ olan alanların izlenmesi, bu değişikliklerin iklim ve canlı sistemler konusu nedeniyle

önemlidir. Bu nedenle AKAÖ sürdürülebilir bir arazi politikası geliştirmeye yardımcı olacak yöntemler arasındadır. Uzaktan algılama (UA), AKAÖ konusunda değişikliklerin haritalanması ve izlenmesi konusunda faydalandığı çoğu çalışmada vurgulanmıştır [Yuan et al., 2005].

1.1. Tezin Amacı, Katkısı ve İçeriği

Tez kapsamında orta konumsal çözünürlükte Sentinel-2A uydu görüntüleri kullanılarak nesne tabanlı sınıflandırma yardımıyla belirlenen çalışma alanlarında arazi kullanımı ve arazi örtüsü değişim tespitinin yapılması ve fark olan alanların tespitine yönelik araştırma ve uygulamalar yapılması amaçlanmaktadır.

Bu çalışmayla elde edilecek haritalar arazi örtüsü ve kullanımının değişiminin tespitini farklı uygulamalarda ve farklı yönleriyle ele alarak incelenmesi sonucu yöntemlerin uygulanabilirliği konusunda değerlendirmeler ve öneriler sunularak katkı sağlanacaktır.


Yapılan çalışmaların içeriği:

- Görüntülerde bulunan nesnelerin sınırlarının çıkarılması ve uygun kenar tespitlerinin yapılması,
- Segmentasyon işleminde ölçek, biçim ve bütünlük parametrelerinin seçimini yapılması,
- Uydu görüntülerinden nesne tabanlı sınıflandırma yaparak segmente edilmiş alanların haritalarının oluşturulması,
- Zamansal olarak farklı tarihlerde elde edilmiş görüntülerden oluşturulan haritaların farklarının alınması,
- Arazi örtüsü ve kullanımı değişiminin zamansal değişiminin tespitinin yapılması olarak belirlenmiştir.

1.2. Metodoloji

Tezin amacına uygun olarak nesne tabanlı değişim analizinin gerçekleştirilmesinde beş temel işlem adımı takip edilmiştir. Bunlar (a) temin edilen uydu görüntülerinin ortalama kayma ve çoklu çözünürlüklü algoritmalarıyla

bölütlenmesi, (b) nesne tabanlı sınıflandırma ile tematik harita üretimi, (c) değişiklik tespiti ve (d) doğruluk analizleridir. Bu işlemlerin gerçekleştirilmesinde eCognition ve QGIS yazılımları kullanılmıştır. Bu çalışmada takip edilen iş akış şeması Şekil 1.1'de gösterilmiştir. İlk işlem adımında iki farklı tarihte kaydedilen Sentinel-2A görüntüleri eCognition yazılımında kullanılan çoklu çözünürlüklü segmentasyon tekniği kullanılarak segmente edilmiştir. QGIS yazılımında kullanılan ortalama kayma segmentasyon tekniği de kullanılarak farklı bir segmentasyon yaklaşımı da değerlendirmeye alınmıştır. Sınıflar ve sınıf hiyerarşisi tanımlandıktan sonra nesne tabanlı sınıflandırma işlemi gerçekleştirilmiş ve tematik haritalar üretilmiştir. Daha sonra iki ayrı zamandaki sınıflandırılmış görüntüler arasındaki değişimler tespit edilmiştir. Yapılan bu çalışmada hazırlanan referans veriler kullanılarak hem sınıflandırma hem de değişiklik tespiti sonuçları değerlendirilmiştir.



Şekil 1.1: Tezde takip edilen iş akışı.

1.3. Literatür Araştırması

Nesne tabanlı sınıflandırma, özellikle yüksek çözünürlüklü görüntülerin kullanılmaya başlamasıyla birlikte birçok uygulamada değerlendirmeye alınan ve başarısı ortaya konulan etkili bir sınıflandırma yaklaşımıdır. Tezin bu bölümünde nesne tabanlı arazi örtüsü değişim tespiti tekniği ile yapılan çalışmalar ele alınmıştır. [Machala and Zejdova, 2014], Çek Cumhuriyeti'nin Güney Moravya'nın yakınlarında 8 km²'lik bir araştırma alanında nesne tabanlı görüntü sınıflandırma tekniğini kullanarak ormanlık alanları yarı otomatik olarak eşleştirmek için çalışma yapmışlardır. Bu çalışmada bir hava dijital kamera ile elde edilen hava görüntüleri (RGB ve NIR bantları) ve LİDAR yükseklik verileri kullanılarak eCognition Developer 8 yazılımında analiz yapılmıştır. Görüntü bölütlemeye çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Sınıflandırma yönteminde ise denetimli en yakın komşu sınıflandırması kullanılmıştır. İlk önce orman olmayan alanlar yani yerleşim alanları, su yüzeyleri ve tarım arazileri sınıflandırılarak, ormanlık alanlar yedi sınıfta temsil edilmiştir. Orman sınıflandırılmasının genel doğruluğu yaklaşık %90 genel doğrulukla Kappa değerini de %85 olarak hesaplanmıştır. Yükseklik bazında 5 m aralıklarla ve %70 üzerinde bir doğrulukla sınıflandırma yapılmıştır.

[Cömert vd., 2017], Antalya ilinin Kumluca ve Adrasan alanlarında nesne tabanlı sınıflandırma tekniğini kullanarak yanmış alanların tespiti için bir çalışma yapmışlardır. Yapılan bu çalışmada Landsat-8 uydu görüntüleri kullanılmıştır. Yanmış alanların çıkarılması için 5 işlem adımı uygulanmıştır. Çalışmanın ilk işlem adımında görüntü kaynaştırma işlemi uygulanmıştır. Bu çalışmanın devamında görüntü kaynaştırma sonucu elde edilen bantlar eCognition Developer yazılımına aktarılıp çoklu çözünürlüklü segmentasyon uygulanmıştır. Daha sonra sınıflandırma için kural setleri geliştirmişlerdir. Geliştirilen kural setleri ile beş sınıf oluşturulmuştur. Bunlar yanmış alan, yeşil bitki alanı (orman, çim, tarım alanları ve yeşil alanlar), su alanı, yerleşim ve sera alanları ve diğer alanlar (toprak, yol, boş alan ve kayalık) olmak üzere beş sınıfta incelenmiştir. Yapılan sınıflandırma işlemi sonucunda genel doğruluğu %89,5 doğrulukla ve yanmış alanların sınıflandırılmasının doğruluğu ise %90 başarı ile elde edilmiştir.

[Yiğit ve Uysal, 2019], Amerika Birleşik Devletleri'nin Nebraska eyaletine bağlı Omaha kentinde afet bölgelerine dair taşkından önce ve sonra olmak üzere arazi

üzerindeki değişimi gösteren çok bantlı uydu görselleri yardımıyla nesne tabanlı sınıflandırma yöntemi kullanılmıştır. Uydu verileri vasıtası ile saptanan taşkın bölgelerine dair afet öncesi ve sonrasında analizler yapılmıştır. Bu çalışma kapsamında uydu olarak Sentinel 2A uydusu baz alınmıştır. Çalışmada uydu görüntülerine çoklu çözünürlüklü segmentasyon yöntemi uygulanmıştır. Segmentasyon işleminden sonra NDWI algoritması kullanılarak taşkın alanlar ve diğer objeler olmak üzere iki sınıfta sınıflandırma işlemi yapılmıştır. Çalışma çerçevesinde ayrıntı çıkarımları ve sınıflandırma neticesinde afet öncesi 2018 yılı içerisinde yaklaşık olarak 63.258 km² olan alanın 2019 senesi içerisinde yaklaşık olarak 101.114 km² olan alanın su ile kaplandığı tespit edilmiştir. 2019 senesinde farklı ay dilimlerinde yapılan veri tespit aşamalarında yaklaşık olarak 1124.893 km², 922.777 km² ve 984.56 km²'lik alanların sel suları ile kaplı olduğu incelenmiştir. Çalışma neticesinde arazi üzerindeki değişimin incelenmesi kapsamında Sentinel 2A uydu verilerinden elde edilen verilerin etkili olduğu saptanmıştır. Yapılan bu çalışma dünya üzerindeki doğal afetlerin sebebiyet verdiği sıkıntılar ve bu sıkıntılar nedeniyle ortaya çıkan bazı felaketlerin ortaya çıkarılmasında uydu teknolojilerinden yararlanılabileceğini göstermektedir.

[Sabuncu ve Sunar, 2017], 23 Ekim 2011 tarihinde Van ilinin Erciş ilçesinde gerçekleşmiş olan 7.2 büyüklüğünde bir deprem sonrası hasar görmüş veya yıkılmış binaların, çadır kentin ve enkaz alanlarının tespiti için nesne tabanlı sınıflandırma yöntemini kullanarak bir çalışma yapmışlardır. Yapılan bu çalışmada depremden bir sonraki günün çalışma alanını kapsayan yüksek çözünürlüklü ortofotolar kullanılarak eCognition yazılımından yararlanılmıştır. Yapılan çalışmada bölgede homojen ve heterojen bir dağılım olduğundan iki farklı çalışma bölgesi seçilmiştir. Çalışmada her iki bölge için çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Nesne tabanlı sınıflandırmada kontrollü ve kontrolsüz sınıflandırma yöntemi kullanılmıştır. Çalışmada toplam dokuz sınıf oluşturulmuştur. Homojen bölgede yeşil alan, yol, bina, tarım alanı, yıkılmış bina, gölge ve açık alan olmak üzere yedi sınıftan oluşmuştur. Heterojen bölgede bina, yol, çadır kent, yeşil alan, açık alan, karışık alan, enkaz ve yıkılmış bina olmak üzere dokuz sınıftan oluşmuştur. Yapılan kontrolsüz sınıflandırma işlemi sonucunda homojen bölge için genel doğruluk %81, kappa katsayısı 0,77 ve heterojen bölge için genel doğruluk %66, kappa katsayısı 0,61 elde edilmiştir. Yapılan kontrollü sınıflandırma işlemi sonucunda homojen bölge için genel doğruluk %92, kappa katsayısı 0,90 ve heterojen bölge için genel doğruluk %71, kappa katsayısı 0,66 olarak elde edilmiştir.

[Cömert vd., 2017], Eskişehir Anadolu Üniversitesi Yunus Emre Kampüsü'nde depremlerin etkisi altına aldığı yapıların yıkılmaları uzaktan algılama yöntemiyle belirlenmesi amaçlanmıştır. Bu araştırma altında depremin meydana gelmesinden sonra binaların yıkılıp yıkılmadığının tespit edilmesi gerekmektedir. Araştırma çerçevesinde insansız hava araçlarına monte edilen kameralar vasıtasıyla yeryüzüne ait birtakım görüntüler elde edilmiştir. Bu elde edilen görüntülerin yardımı ile yapılan araştırma doğrultusunda çeşitli bilgilerin ortaya çıkması beklenmiştir. Bu araştırmada 2014 ile 2015 yıllarında yüksek çözünürlüklü görseller insansız hava araçları vasıtasıyla elde edilmiştir. Yapılan çalışmada nesne tabanlı sınıflandırma yöntemi eCognition Developer 9 kullanılmıştır. Nesne tabanlı sınıflandırmada çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Bina çıkarımında on tane bant endeksi kullanılmıştır. Yapıların yıkılıp yıkılmadığının tespiti bir senaryo üzerinden yapılmıştır. Bu bağlamda 2014 senesinde elde edilen görseller deprem sonrası ve 2015 senesinde elde edilen görseller deprem öncesi olarak sınıflandırılmıştır. Çalışmada 2014 ve 2015 yıllarına ait görseller işlenmiştir. Bununla birlikte çalışma alanına ait ortofoto görüntüleri ile sayısal yükseklik modeli ortaya çıkarılmıştır. Elde edilen bu veriler nesne tabanlı sınıflandırma yaklaşımı altında değerlendirilmiştir. Çalışma sonucunda iki yıla ait çalışma alanı kapsamındaki binaların varlıkları tespit edilmiştir. 2014 senesinde çalışma yapılan alanda bulunmayan 11 yapının bulunduğu tespit edilmiştir. Araştırma nesne tabanlı sınıflandırma yaklaşımı ile insansız hava araçlarının başarıyla kullanıldığını ortaya koymuştur.

[Delen ve Şanlı, 2017], İzmir ili Menemen ilçesinde tarımsal ürün desenini gösteren tematik haritaların oluşturulması için nesne tabanlı sınıflandırma yöntemini kullanarak çalışma yapmışlardır. Yapılan bu çalışmada RapidEye uydu görüntüsü kullanılmıştır. Araziden eğitim ve test verileri toplanmıştır. Çalışmada yedi sınıf oluşturulmuştur. Bunlar farklı mısır türleri (Mısır1, Mısır2, Mısır3), Pamuk, Su, Diğer Bitkiler, Bitki olmayan (yerleşim alanları ve yollar) sınıflar olmak üzere yedi sınıfta incelenmiştir. Segmentasyon işleminde çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Sınıflandırmada en yakın komşuluk algoritması kullanılmıştır. Yapılan sınıflandırma işlemi sonucunda genel doğruluğu %93,33 ve kappa katsayısını 0,917 olarak elde edilmiştir.

2017 yılı içerisinde yapılan araştırma kapsamında Sentinel 2 uydu görüntülerinden yararlanılarak nesne tabanlı sınıflandırma tekniği kullanılarak Gediz Ovası'na ait mahsullerin saptanması istenmiştir. Bu kapsamda saptanan mahsulleri

patlıcan, mısır ve biber meydana getirmektedir. Çiftçi kayıt sisteminde elde edilen veriler yardımıyla yer gerçeği verileri elde edilmiştir. Çiftçi kayıt sistemi içerisinde yer alan veriler parsel olarak kontrol edilerek arazi çalışmaları onaylanmıştır. Rastgele orman algoritması kullanılarak sınıflandırma işlemleri gerçekleştirilmiştir. Bununla birlikte sınıflandırma işlemleri segment altyapılı olarak gerçekleştirilmiştir. Çalışma alanlarını kapsayan 8 tane uydu görüntüsü verileri ele alınmıştır. Uydu görüntülerinin her biri için NDVI bantları meydana getirilmiştir. Sınıflandırma işlemi yapılmadan önce NDVI bantları ve orijinal bantlar yardımı ile çoklu çözünürlüklü görsel segment işlemleri yapılmaya başlanmıştır. Bununla birlikte her bir görsel bölüm için doku ölçümleri entropi, fark ve homojenlik üretilmiştir. NDVI bantlarının yardımıyla nesne tabanlı orman algoritması sınıflandırma işlemleri oluşturulmuştur. Yapılan araştırma sonucunda standart sapma ve doku bantlarının araştırmanın doğruluğunu arttırmadığı gözlemlenmiştir. Buna karşın ufak çaplı bir azalma söz konusu haline gelmiştir. Kappa katsayısı en büyük çıkan kombinasyonu NDVI bantları olarak oluşturulmuştur [Yılmaz, 2018].

[Yiğit ve Kaya, 2020], Düzce ilinin Akçakoca ilçesinde Melen Nehri üzerinde sel taşkınları alanlarının saptanması için uzaktan algılama yöntemlerinden yararlanılarak sel sonrasında yaşanan tehlikeli durumlar gözlemlenmiştir. Yapılan araştırma kapsamında Düzce’de ortaya çıkan sel felaketlerinin ortaya çıkardığı taşkın alanları uydu görüntüleri vasıtası ile analizleri yapılmıştır. Sel etkisinde kalan araziler Sentinel 2A uydu görüntüleri yardımıyla nesne tabanlı sınıflandırma kullanılarak elde edilmiştir. Çalışma da eCognition yazılımında çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Altı farklı tarihlerde alınan uydu görüntüleri kullanılarak saptanan selin tahribat verdiği alanlar alan altyapılı olacak şekilde belirlenmiştir. Araştırma esnasında saptanan alanın su miktarı, selden önceki ve sonraki durumlarda farklılıklar meydana getirdiğini ortaya koymaktadır. Bununla birlikte uydu görüntülerinden elde edilen veriler sayesinde sele sebebiyet veren fazla suyun kısa bir zaman diliminde nehir yatağına geri dönüş yaptığı incelenmiştir.

Uzaktan algılama teknolojileri tarımsal uygulamalarda yaygın bir kullanıma sahiptir. Bu uygulamaların başında tarımsal ürün desenlerinin belirlenmesi gelmektedir. Tarım alanlarında rekolte ve verim tahminleri ürünlerin geliştirilmesi ve planlanması aşamasında oldukça etkili olan seçenekler arasında yer almaktadır. [Torunlar vd., 2021], Konya ilinin Karapınar ilçesinde Sentinel 2A uydu görüntülerinden yararlanarak tarımsal ürün desenlerinin belirlenmesi amacıyla bir

çalışma yapmışlardır. Bununla birlikte tarımsal ürün deseninin belirlenmesi için nesne tabanlı sınıflandırma tekniğinden yararlanılmıştır. Yapılan çalışmada çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Bununla birlikte segmentasyon algoritmasını kapsayan yoğunluk, şekil ve ölçek parametrelerinin belirlenmesi amaçlanmıştır. En yakın komşuluk algoritması segmentlerin sınıflandırılması amacı ile kullanılmaya başlanmıştır. Sınıflandırmayı daha basit hale getirmek amacıyla NDVI ve DVI gibi yardımcı verilerden yararlanılmıştır. Genel doğruluk oranı %82 olarak hesaplanırken kappa katsayısı ise 0,76 olarak hesaplanmıştır. Bununla beraber bu araştırma da sınıflandırma performansının üst düzey olduğu saptanmıştır. Buna göre tarımsal ürünlerin desenlerinin belirlenme aşamalarında nesne tabanlı sınıflandırma tekniğinin yüksek doğruluk içeren neticeler verdiği ortaya çıkmıştır.

[Marangoz vd., 2005], Zonguldak ilinin sanayi bölgesinde yol ve binaların çıkarımı için nesne tabanlı sınıflandırma tekniğini kullanarak bir çalışma yapmışlardır. Yapılan bu çalışmada yüksek çözünürlüklü IKONOS pan-sharpened görüntüleri kullanılarak eCognition yazılımından yararlanılmıştır. Kullanılan Ikonos görüntüsü PCI yazılımında pan-sharpening metodu uygulanarak geliştirilmiştir. Segmentasyon aşamasında çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Çalışmada yedi sınıf oluşturulmuştur. Sınıflandırma sonucu bina ve yolların ortaya çıkarılabildiği görülmüştür. 0,84 kappa değeri yapılan çalışmada beklenen değeri karşıladığı görülmüştür.

[Hölbling et al., 2012], SAFER (Acil Müdahale için Hizmetler ve Uygulamalar) proje kapsamında geliştirilen heyelan tespiti ve sınıflandırılması için yarı otomatik nesne tabanlı bir yaklaşımı Kuzey-Batı İtalya'da Mont de la Saxe'de bir vaka çalışmasında uygulamışlardır. Yapılan çalışmada Mayıs 2005'te çekilen SPOT-5 görüntüleri ve türev eğimi, yönü, eğriliği dahil olmak üzere bir dijital yükseklik modeli (DEM) kullanılmıştır. Çalışma alanı içerisinde dik arazi özelliklerinden dolayı Mont de la Saxe'nin kuzey yamacını da içeren bazı taraflarında gölge olduğundan sınıflandırmada dikkate alınmamıştır. Nesne tabanlı sınıflandırma için uzaysal ve morfolojik özelliklerin yanı sıra bağlam bilgisi de kullanılmıştır. Segmentasyon işleminde çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Ölçek parametresini objektif olarak seçmek için ESP (ölçek parametresinin kestirimi) adlı bir istatistiksel bir araç kullanıldı. İlk işlem olarak heyelan, benzer spektral özelliklere sahip diğer özelliklerden ayırmak için kaba bir segmentasyon seviyesinde sınıflandırılmıştır. Daha sonra sınıflandırma akışa benzer toprak kaymaları ve diğer heyelan türleri olarak

ince bir segmentasyon seviyesinde geliştirildi. Toplamda 3,77 km²'lik bir alanda, 1,68 km² alan akışa benzer heyelanlar (esas olarak kanalize edilmiş enkaz gövdeleri ve bunların çökelme alanları) ve 2,09 km² alan diğer heyelan türleri (düşmeler, tepeler, kaymalar ve yayılmalar) olarak sınıflandırılmıştır. Bazı bölgelerde gölgeli alanlarla sonuçlanmış ve bu alanlarda heyelanları tespit etmek zor olmuştur. Bu engellerden başka küçük heyelanlar tespit edilememiş ve yanlış sınıflandırılmış parçalar meydana gelmiştir. Bu hataları düzeltmek için manuel olarak düzenleme yapılmıştır. Sonuçlar önceden var olan heyelan envanter verileri (IFFI ve PAI) ve ERS1/2, ENVISAT ASAR ve RADARSAT-1 verilerinden türetilen PSI (Kalıcı Saçılım İnterferometri) ölçümlerinin bir yorumu ile karşılaştırılmış ve doğrulanmıştır. Tespit edilen heyelanların mekânsal benzerliği ve mevcut heyelanları sırasıyla %44,8 (IFFI) ve %50,4 (PAI) olarak tespit edilmiştir.

[Polat ve Kaya, 2021], Şanlıurfa'da bulunan Harran Üniversitesi Osmanbey kampüsünde meydana gelen yangınlar sonrası hasar tespiti için çalışma yapılmıştır. Yapılan çalışma kapsamında ESA'nın (Avrupa Uzay Ajansı) sağlamış olduğu Sentinel 2 uydu görüntüleri kullanılmıştır. Araştırmanın asıl gayesi yangın bölgesi saptanarak, saptanan bölgede belirlenen hasarların durumlarına göre sınıflandırmalar yapılmasıdır. Bununla birlikte hasar bölgelerinde meydana gelen bitki örtüsü değişikliğinin de incelenmesi amaçlanmıştır. Bu amaç doğrultusunda yangın indeksi ve bitki indeksi görselleri ortaya çıkarılarak yangın alanı belirlenmiştir. Bununla birlikte hasar durumlarına göre sınıflandırmalar yapılarak hasar sınıflarındaki bitkilerin değişimleri saptanmıştır. Bu işlemlerin ardından bitki yoğunluğu ve hasar durumu gözlemlenerek bitkilerin yoğun halde bulunduğu bölgeler harita olarak sunulmuştur. Çalışma neticesinde çalışma alanında yaklaşık olarak 55 hektar alanın yangından çeşitli seviyelerde etkilendiği ortaya çıkmıştır. Bununla birlikte çeşitli bitki yoğunluğunun bulunduğu bölgelerdeki ziyanların bulunduğu rapor edilmiştir.

[Marangoz vd., 2013], Sakarya'nın Karasu ilçesindeki kıyı şeridindeki zamansal analizleri nesne tabanlı sınıflandırma tekniği kullanarak bir çalışma yapmışlardır. Yapılan çalışmada farklı zamanlarda çekilmiş Landsat uydu görüntüleri kullanılmıştır. Sonuçları değerlendirmek için Ocak 2010 yılında kıyı şeridinde GNSS ölçmeleri de kullanılmıştır. Bu çalışmada eCognition yazılımından yararlanılıp segmentasyon ve sınıflandırma aşamaları gerçekleştirilmiştir. Nesne tabanlı sınıflandırma yönteminde bulanık mantık üzerine çalışma yapılmıştır. Sınıflandırma da deniz ve kara sınıfları oluşturulmuştur. Sınıflandırma sonucu genel doğruluk %80-83 ve Kappa değeri 0,80-

0,83 elde edilmiştir. Nesne tabanlı sınıflandırma işlemlerinden sonra CAD ortamında elle detayların sınırları çizilmiştir. Sınıflandırma yaklaşımı ve ekran üzerinden elle vektörleştirme yaklaşımı sonuçlarından elde edilen vektör sonuçları bir CBS yazılımında yıllara göre alınan görüntülerden bölgenin 1/5000 ölçekli topografik haritasında elde edilen kaynak vektör sonuçları ile karşılaştırılmıştır. Elde edilen sonuçlara göre kıyı şeridinin yarı otomatik olarak çıkarımının hızlı bir şekilde yapılabildiği, nesne tabanlı sınıflandırma tekniği ile ekran üzerinden elle vektörleştirme sonuçlarının benzer olduğu görülmüştür.

[Aydemir, 2018], Güneydoğu Anadolu Bölgesi'nde yer alan Harran Ovası içerisinde bulunan tarım alanlarında izinsiz yapılaşmanın tespiti üzerine bir çalışma yapmıştır. Bu çalışma kapsamında 1995 yılından 2017 yılına kadar uzaktan algılama ile coğrafi bilgi sistemleri kullanılarak çalışmalar yürütülmüştür. Bu çalışmada ovaların sulamaya açılması ve arazilerin kullanımlarının plan aşamalarının değerlendirilmesi istenmiştir. Araştırma yapılması beklenen alan içerisinde yer alan tarım arazileri üzerindeki kentleşmenin uydu görüntülerinin sınıflandırılması ve analizi yapılmıştır. Bununla birlikte nesne tabanlı sınıflandırma tekniği ile geleneksel sınıflandırma tekniği arasında karşılaştırmalar yapılmıştır. Bu kapsamda çalışmanın yürütüldüğü alanın 2017 senesine ait SPOT uydu görüntüleri elde edilmiştir. Nesne tabanlı sınıflandırma tekniği ile piksel tabanlı sınıflandırma tekniği ile arazi kullanım şekilleri ortaya çıkarılmıştır. Nesne tabanlı ve piksel tabanlı sınıflandırma tekniklerinin neticelerinin doğruluk kontrolleri yersel veriler ile karşılaştırılması sonucu elde edilmiştir. Bu sonuç kapsamında sulama öncesi ve sulama sonrası vaziyet ortaya konularak kentleşmenin yoğun şekilde görüldüğü alanlar saptanmıştır. Çalışma sonucunda araştırmanın yapıldığı alan içerisinde sulama sonrası aşağı yukarı 5000 hektarlık bir alan içerisinde kentleşme de artış olduğu incelenmiştir.

Uydu görüntülerinin tarımsal arazilerde ürünlerin oluşumunun belirlenmesi konusunda çoğunlukla tercih edilen bir yöntem olarak günümüzde karşımıza çıkmaktadır. [Tavus vd., 2019], çözünürlüğü yüksek olan IKONOS uydu görüntülerinden tarımsal alanlarda ürün deseninin belirlenmesi için Bursa ilinin Karacabey ilçesinin 81 km²'lik bir alan üzerinde bir çalışma yapmışlardır. Bu çalışmada nesne tabanlı sınıflandırma tekniği uygulanmıştır. Çalışma alanında şeker pancarı, buğday, biber ve pirinç gibi mahsullerin yetiştiği gözlenmiştir. Çalışma çerçevesinde IKONOS uydu görüntüleri çoklu çözünürlük segmentasyon yöntemi ile bölümlendirme işlemleri gerçekleştirilmiştir. Segmentasyon işleminde ölçek parametresi için

kullanılması gereken deęer Estimation of Scale Parameter (ESP-2) yazılımı yardımıyla gerekleşmiştir. Yapılan deneme analizleri sonucunda bütünlük ve şekil parametreleri saptanmıştır. Sınıflandırmanın doğruluk derecesini arttırmak amacı ile görsel dijital bantlarına ilave olarak NDVI bandı ile çeşitlilik, varyans, ortalama ve homojenlik unsurları göz önünde bulundurulmuştur. Sınıflandırma bandı aşaması 29 bantlı veri seti kullanılarak yapılmıştır. Sınıflandırma neticesinde yaklaşık olarak 2212 tane yer gereęi verileri kullanılmıştır. Sınıflandırmanın doğruluk derecesi doğruluk analizleri sonucunda yaklaşık olarak %87,5 gibi bir deęer olarak hesaplanmıştır. Yapılan alıřma sonucunda IKONOS uydu görüntüsü üzerinden tarımsal ürünlerin deseni saptanmıştır. Bununla birlikte nesne tabanlı sınıflandırma yöntemi ile doğruluk derecesi yüksek sonuçlar ıkabileceęi gözlemlenmiştir.

[İrfanoęlu ve Balık, 2018], İstanbul ilinin atalca ilçesinde arazi örtüsü/ arazi kullanımı sınıflarının belirlenmesi üzerine bir alıřma yapmışlardır. Bu alıřma da Sentinel 2 multispektral aygıt (MSI) uydu görüntüleri kullanılmıştır. Nesne tabanlı sınıflandırma yöntemi yardımıyla arazi örtüsü ve arazi kullanımı sınıflarının belirlenmesi hedef odaęı haline gelmiştir. Bununla birlikte arazi örtüsü ve arazi kullanımı sınıflarının belirlenmesi amacıyla oklu özünürlüklü segmentasyon algoritması ile nesne tabanlı sınıflandırma yapılmıştır. alıřma içerisinde yapılan bu işlem için kompaktlık, şekil ve ölek adında üç eşit parametre en küçük nesne şekli hesaba katılarak deęerlendirilmiştir. EYK (En Yakın Komşuluk) algoritması, alıřma kapsamında görüntüleri sınıflandırma amacı için kullanılmıştır. Sentinel 2 uydu görüntüsünün mavi, NIR bantları, yeşil ve kırmızı bantları kullanılarak sınıflandırmanın doğruluęunun artırılması amaçlanmıştır. Ortaya ıkan sınıfların doğruluk deęerlendirme uygulamaları hata matrisi yardımıyla gerekleşmiştir. Bununla birlikte alıřma sonucunda kappa katsayısı 0,89 olarak ve genel doğruluk deęeri %91,3 olarak hesaplanmıştır.

[Tassi et al., 2021], Orta İtalya'nın Abruzzo bölgesinde bulunan Maiella Ulusal parkının arazi kullanımı/ arazi örtüsü haritasının üretilmesi için, Google Earth motorunda Landsat 8 uydu görüntülerinden veri kompozisyonu ve sınıflandırma süreci geliştirmeyi amaçlayan bir alıřma yapmışlardır. Bu alıřmada 2018, 2019 ve 2020 yıllarındaki geniş yapraklı ormanlar, boş toprak veya kayalar, otlaklar, alılar, ięne yapraklı, eğrelti otları, seyrek bitki örtüsü olan alanlar, meralar, tarım ve yerleşim alanlarını sınıflandırma sınıfları olarak seçilmiştir. İki piksel tabanlı ve iki nesne tabanlı yaklaşımın sınıflandırma doğruluklarını karşılaştırarak, L8 verilerini

kullanarak seçilen arazi kullanımı/ arazi örtüsü sınıflarını belirlemek için bir yöntem yapılandırılmıştır. Tarım alanlarının sınıflandırılmasını iyileştirmek için, yardımcı veri olarak 2018 Corine Arazi Örtüsü (CLC) katmanı eklenmiştir. Yapılan uygulamada zaman zaman ağaç sayısı arttırılarak rastgele orman sınıflandırıcıları eğitmişlerdir. Sınıflandırıcıyı eğitmek ve LULC sınıflandırma sonuçlarını doğrulamak için karşılıklı minimum 500 m mesafe ile 1200 rastgele dağıtılmış nokta toplamışlardır. %70'ini rastgele orman sınıflandırıcıyı eğitmek için ve %30'unu doğrulama aşaması için kullanılmıştır. L8 15-m pankromatik bant kullanılarak nesne tabanlı yaklaşım en iyi performansı ve en düşük değeri gösterdiğini saptamışlardır. Nesne tabanlı yaklaşımı içinde pankromatik bandı kullanarak, çalışma alanının ayrıntılı, 15 m çözünürlüklü bir arazi kullanımı/ arazi örtüsü haritası üretilmiştir.



2. UZAKTAN ALGILANMIŞ GÖRÜNTÜLERİN SINIFLANDIRMASI

2.1. Görüntü Sınıflandırma

Sınıflandırma işlemi verilerle çalışan çoğu disiplinin kullandığı veri dönüşüm işlemidir. Kategorize edilmiş verilerin içerisinde anlamlı bilgiler edinmeyi amaçlayan tanımlama sürecidir [Tonbul,2021]. Arazi kullanımı ve arazi örtüsünün uydu görüntülerinden elde etme işinde önemli bir adımdır. Uzaktan algılamada görüntülerdeki pikselleri bir sınıfa atama işlemi olarak tanımlayabiliriz. Sınıflandırmanın görüntüde yapılması çok yüksek işlem ve görüntülerin yapısı gereği zor bir işlemdir [Kavzoğlu,2001].

Uydu görüntülerinde veri setine uygun bir şekilde seçilen tekniklerle başarılı bir şekilde kullanılabilir [Çölkesen,2015]. Sınıflandırma probleminin mevcut verilerden elde edilmesi amaçlanan bilgilerin çıkartılması dikkat gerektiren bir iştir [Kavzoğlu,2001].

Görüntü sınıflandırmanın amacı görüntü üzerinde bulunan piksellere doğru sınıflara atama işleminin yapılmasıdır. Basit olarak tek bir spektral bant üzerinde eşik değeri kullanılarak yapılabilmesinin yanında çok bantlı görüntülerde karmaşık kurallara eşlik edebilmektedir [Jensen and Gorte,2001]. Bu teknikler genel olarak tek tarihli görüntülerde veya çok tarihli görüntülerde spektral verilerin üzerinde uygulanmaktadır [Sabin,1997].

İlerleyen teknolojiyle birlikte yeni sınıflandırma yöntemleri ortaya çıkmıştır. Piksellerin değil nesnenin ön planda olduğu, dokunun istatistiksel olarak anlamlı hali ve şekilsel olarak topolojik özelliklerin yakın ilişkisine bakılarak nesne yönelimli yöntemler üretilmiştir [Das,2009]. Sınıflandırma işlemi piksel veya nesne tabanlı olmak üzere ikiye ayrılmaktadır. Yeryüzü hakkında bilgi edinmek için uzaktan algılanmış görüntüler üzerinden yapılan sınıflandırma işlemlerinin sonucunda tematik haritalar elde edilmektedir. Bu haritalar günümüzde çeşitli alanlarda ve coğrafi bilgi sistemlerinde kullanılmaktadır.

2.1.1. Piksel Tabanlı Sınıflandırma


Uzaktan algılanmış görüntüler yardımıyla yeryüzü nesnelere ilişkin bilgi çıkarımında en sık kullanılan yöntem sınıflandırmadır. Görüntüdeki piksellere ilişkin parlaklık ve yansıma değerleri kullanılarak piksellerin uygulayıcı tarafından belirlenen sınıflara atanması işlemi genel olarak sınıflandırma olarak bilinir. [Sabuncu ve Sunar,2017].

Sınıflandırma işlemi kontrollü ve kontrolsüz sınıflandırma olarak iki grupta değerlendirilmektedir. Kontrolsüz sınıflandırma görüntüyü oluşturan bantlar ve pikselleri değerlendirerek ve kontrollü sınıflandırma seçilen piksellerin hangi sınıfa atanacağını önceden belirlenerek yapılmasıdır [Çölkesen,2015].

2.1.2. Nesne Tabanlı Sınıflandırma

Son yıllarda uydu görüntülerinin ve hava fotoğraflarının yüksek çözünürlükle elde edilmesi ve görüntülerde bilgi içeriğinin zengin olması sebebiyle piksel tabanlı sınıflandırma yönteminin tematik harita üretiminde yetersiz kalmasına neden olmuş ve ile nesne tabanlı sınıflandırma yönteminin yaygın bir şekilde kullanımını ortaya çıkarmıştır [Navulur,2007].

Nesne tabanlı sınıflandırma yönteminde genel iş akışı Şekil 2.1’de gösterilmiştir. Şekilden de görüleceği üzere nesne tabanlı sınıflandırma yönteminde ilk işlem adımı görüntü bölütleme veya segmentasyon olarak bilinen işlemdir. Segmentasyon işleminin ardından görüntü üzerindeki nesnelerin özellikleri tanımlanır. Nesnelerin tanımlanmasında her bir nesne içerisindeki piksellerine ait standart sapma, ortalama, maksimum, minimum değerlerinin yanı sıra sınıflandırma görüntü nesneleri arasındaki komşuluk, uzunluk, alan gibi özelliklerde dikkate alınabilmektedir [Çölkesen,2015]. Nesnelerin özelliklerinin tanımlanmasından sonra sınıflandırma için eğitim ve test verileri tanımlanması işlemi gerçekleştirilir. Eğitim ve test verileri kullanılarak sınıflandırma modeli üretilir. Söz konusu modelin tüm görüntüye uygulanması ile tematik harita üretilir.



Şekil: 2.1: Nesne tabanlı sınıflandırma yönteminin iş akışı.

2.2. Görüntü Bölütleme (Segmentasyonu)

Segmentasyon nesne tabanlı sınıflandırma yönteminde ilk işlem adıdır. Bölütleme görüntü üzerinde aynı özelliklere sahip piksellerin gruplanması ve nesnelerin veya alanların oluşturulması işlemidir. Segmentasyonun amacı görüntülerden anlamlı görüntü nesneleri üretmek ve birbirinden farklı bölümlere ayrılmasıdır [Baatz and Schape,2000]. Segmentasyon işleminde aşağıdan-yukarıya (bottom-up) ve yukarıdan-aşağıya (top-down) olmak üzere bilinen iki temel yöntem vardır [Definiens,2012]. Yukarıdan-aşağıya yönteminde bir parçanın en küçük parçalara bölünmesi esasına dayanmaktadır. Segmentasyon işleminin gerçekleştirilmesinde satranç tahtası segmentasyon (chessboard segmentation), dörtlü ağaç tabanlı segmentasyon (quadtree-based segmentation) ve kontrast bölümlenmesi segmentasyon (contrast split segmentation) olmak üzere yukarıdan-aşağıya yönteminde kullanılan üç farklı segmentasyon metodu mevcuttur. Satranç tahtası segmentasyon algoritması, görüntüyü uygulayıcı tarafından belirlenen eşit boyutlarda kare olarak parçalara ayrılmasıdır. Dörtlü ağaç tabanlı segmentasyon algoritması, bir görüntüyü satranç tahtasına benzer şekilde ancak eşit değil farklı boyutlarda parçalara ayırır. Kontrast bölümlenmesi segmentasyon algoritması, bir eşik değeri seçilerek görüntünün kontrast farkı maksimum olacak şekilde açık ve koyu renkli görüntü objelerine ayrılmasıdır.

Segmentasyon işleminde bir diğer yöntem olan aşağıdan-yukarıya stratejisi, küçük parçaların belirli ölçütler dikkate alınıp birleştirilerek büyük parçalar elde

edilmesidir. Aşağıdan-yukarıya yaklaşımında kullanılan yaygın olarak kullanılan yöntem çoklu çözünürlük segmentasyon (multiresolution segmentation) yöntemidir [Baatz and Schape,2000; Benz et al.,2004]. Çoklu çözünürlük segmentasyon yöntemi, ilk önce her bir pikseli bir obje olarak değerlendirmeye alıp daha sonra her bir pikseli belirli homojenlik ölçütlerine yani şekil ve renk ölçütlerinin birleşimi olan ölçek parametresini esas alarak komşu pikselleri birleştirerek görüntü objeleri elde edilmesi esasına dayanmaktadır [Çölkesen,2015]. Çoklu çözünürlük segmentasyonda üç önemli parametre vardır. Bunlar ölçek, renk/şekil ve yumuşaklık/yoğunluk parametreleridir. Bu parametreler mümkün olabildiğince gerçeğe yakın belirlenmelidir. Renk, şekil parametresi nesneleri üretirken birbirleri arasındaki uyumsuzluğu giderebilir. Yumuşaklık/yoğunluk parametresi renk/şekil parametresinin değerine göre uygulayıcının nesnelerin yumuşak veya yoğun olması gerektiğine karar verebilir. Ölçek parametresi nesne boyutunu etkiler ve nesnelerin homojenliğini veya heterojenliğini ölçer. Ölçek parametresi arttıkça nesnelerin boyutları artar ve büyük görüntü objeleri üretilir, parametre değeri azaldıkça küçük ve fazla görüntü objeleri üretilir. Nesne tabanlı sınıflandırma yönteminde optimum ölçek parametresinin belirlenmesi sınıflandırma sonucunda üretilecek olan tematik haritanın doğruluğunu ve sınıflandırma işleminin işlem sürecini doğrudan etkileyen bir öneme sahiptir.

Segmentasyon işleminde uygulanan başka yöntemler de vardır. Noktaya dayalı değişim yaklaşımları histogram tabanlı segmentasyon yöntemleri olarak da isimlendirilir. Çünkü bu yöntemlerde görüntünün histogramına bakarak bir veya birden fazla global eşik bulunur ve bu eşikleri uyguladıktan sonra bölümler elde edilir. Bu tür yöntemlerde küresel bilgileri kullanmak ve yerel bilgileri silmek nedeniyle bölümlere ayırma bağlamında bağlamsal bilgiler kullanılmaz. Bu nedenle bölümlendirmeden sonra içeriksel bilgileri birleştirmek için tamamlayıcı bir algoritma kullanmak gereklidir. Nokta tabanlı yaklaşımlar yüksek uzaysal çözünürlükteki nesnelerin sınıf içi değişimi çok yüksektir. Bu uygunsuzluk içinde gösterilmiş olandan alınan örnek bir bölümlendirme ile netleştirilebilir. Ayrıca, bu yöntem sınıfının önceden bölümlerin sayısını denetlemesi gerekir ve bu yaklaşımların en büyük dezavantajıdır [Şahin,2013].

Kenar tabanlı segmentasyon yöntemi nesnelerin sınırlarının çıkarılması için kullanılır. Sınır çıkarımında kenar algılama ve kapalı konturların üretilmesi adımı vardır. Görüntünün kenarları kenar algılama algoritmalarıyla süreksizlik özelliği kullanılarak çıkarılır. Bu adımdan sonra elde edilen konturlar yoğunlukla kapalı

değildir. Kapalı nesne sınırlarına ulaşmak için yardımcı bir kontur kapama yaklaşımı gereklidir [Carleer et al.,2005]. Kenar detektörü algoritması kullanılır. Bu işlem üç ana adım içerir. İlk adım olarak, görüntü gradyan görüntüyü elde etmek için Canny-Deriche operatörü tarafından filtrelendir. İkinci adım, tutarlı sınırları korumak için bir histerez eşikleme uygulanır. Son adımda ise görüntüdeki konturlar en iyi sayımı sağlayacak şekilde kapatılır. Bir şekilde sayım bu yoldaki gradyan değerlerini toplayarak hesaplanır. Ayrıca görüntü morfolojisine dayanan havza segmentasyonu, kenar temelli yaklaşımları kategorisinde yer alabilir.

Bölgesel bölütleme algoritmasında mekânsal olarak bağlı piksel kümesi olarak tanımlanan ve önceden tanımlanmış bir homojenlik ölçüsüne göre homojen bölgeler bulunur. Bölgesel segmentasyon yaklaşımında üç temel segmentasyon yöntemi vardır. Bunlar; bölge büyüme / birleştirme, bölme ve bölme ve birleştirme yöntemleri vardır. Bölge büyüme/ birleştirme yönteminde eldeki segmentler ilk segmentasyon adımından sonra bulunur, homojenlik ölçüsüne göre mekânsal olarak komşu ve benzer bölümlerle birleştirilir. Bu segmentler bir piksel segmenti olabilir. Bölme yönteminde bütün görüntü ilk başta bir heterojen bölge olarak alınır. Daha sonra seçilen tüm homojenlik kriterine göre tüm parçalar homojen olana kadar her bir heterojen görüntü bölgesi dikdörtgen bir şekilde dört parçaya bölünür. Bölme ve birleştirme yönteminde bölme işlemlerinden farklı olarak bölme işlemi sona erdiğinde benzer komşu bölgeleri birleştirmek için bir birleştirme işlemi başlatılır. Bu yöntemlerin en büyük dezavantajı sınır bozulmasıdır. Sürekli olarak dikdörtgen biçimli sınırlar oluşturma eğilimindedir. Bu yöntemlerde en kritik nokta iyi bir homojenlik ölçüsüdür [Haris et al.,1998].

Literatürde bulunan hibrit bölütleme algoritması noktaya dayalı, kenar tabanlı ve bölgesel segmentasyon yaklaşımlarını kendi başlarına kullanırken eksiklikleri gidermek için birleştirmek ve segmentasyon problemlerine ileri bir çözüm sunmaya çalışır. Çoğu zaman kenar ve bölgeye dayalı segmentasyon teknikleri birlikte kullanılır [Haris et al.,1998].

Objeye-arka plan modeli algoritmalarında histogram eşikleme yaklaşımı kullanılır. Tekil pikseller kullanıldığından görüntünün spektral özellikleri çokça kullanılır. [Dey et al.,2010].

Rastgele alan modeli bölütlemesi yüksek çözünürlüklü uydu görüntüleri için iyi bir yaklaşımdır ancak hızlı otomatikleştirme gerektiren uygulamalarda uygun değildir. Karmaşık hesapları uzun zaman dilimine ve çalışma yapmadan önce görüntü hakkında bilgiye ihtiyaç duyar [Haris et al.,1998].

Bulanık model bölütleme için bulanık kümeleme kullanılır. Her nokta bir kümeye ait olan geleneksel kümelemeye göre bulanık kümelemede her bir nokta her bir kümeye belirli bir olasılıkta aitliği vardır. Bu olasılıklara noktanın küme katsayıları denir. Literatürde mevcut olan çoğu bulanık segmentasyon yöntemi, Bulanık Merkez Ortamı (veya Bulanık C-Orta veya FCM) kümelemesi ve bulanık eşiklemeye dayanmaktadır [Shankar,2007]. Bulanık merkez ortamı kümelemesi yaklaşımı dört adımda tanımlanır. İlk adımda küme sayısı belirlenir. İkinci adımda her bir noktanın küme katsayılarını rastgele bir şekilde atanır. Üçüncü adımda her bir kümenin sentroidi hesaplanır ve her bir noktanın küme katsayıları yeniden hesaplanır. Son adımda ise yakınsamaya kadar olan üç adım yinelenir (ardışık katsayı değişikliği belirtilen bir eşikten daha fazla değildir) [Bezdek,1981]. Bu yöntemin temel dezavantajları karmaşıklığı ve küme sayma bilgisinin gerekliliğidir.

Sinir ağları modeli gerçek zamanlı üretim ve rastgele oluşan gürültülere karşı direnç gösterme özelliğine sahiptir [Shankar,2007]. Bu model eğitim işleminden sonra sistem girdilerine göre bir model üretir ve öğrendikleriyle anlamlı çıktılar oluşturur. Sinir ağları modeli eğitim işleminden dolayı denetimli yaklaşım olarak da bilinir.

Havza modelinde öncelikle görüntü eğim görüntüsüne dönüştürülür. Daha sonra eğim görüntüsü piksellerin yoğunluk değerlerinin karşılık gelen noktaların yüksekliklerini gösterdiği yeryüzü yorumlanır [Smet and Luis,2000]. Havza modeli segmentasyonu genellikle fazla bölümlere ayrılmış sonuçlar verir ve bu nedenle genel görüntü segmentasyon sisteminde tek başına kullanılmaz. Bu yöntem ile yardımcı bir yöntem ya ön işlem adımı ya da işlem sonrası adımı olarak kullanılır. Yüksek çözünürlüklü uydu görüntülerinde kayda değer bir doku vardır. Bu görüntüler aşırı segmentasyon problemini daha da kötüleştirir. Kötüleştiren diğer bir faktör de gürültüdür. Buna çözüm olarak düzleştirme yöntemleri veya bölge birleştirme yöntemleri tak başına ya da birlikte, genellikle literatürde sırasıyla ön işleme veya işleme sonrası olarak kullanılır [Şahin,2013].

3. UZAKTAN ALGILANMIŞ GÖRÜNTÜLER YARDIMIYLA DEĞİŞİM TESPİTİ

Değişim tespiti bir nesneyi veya olguyu farklı zamanlarda gözlemleyerek durumundaki farklılıkları belirleme sürecidir [Singh,1989]. Dijital değişim saptama uzaysal, tematik, spektral ve zamansal kısıtlamalardan etkilendiğinden ve birçok değişiklik saptama tekniği kullanıldığından, belirli bir araştırma projesi için uygun bir yöntem seçimi önemlidir ancak kolay değildir. Çalışma projelerinde karmaşıklığı azaltmak için değişiklik tespit yöntemlerini dört kategoride gruplandırılmıştır.

3.1. Görüntülerin Cebirsel Farklarıyla Değişim Analizi

Cebir farklar değişim tekniklerinde görüntü farklılığı, görüntü regresyonu, görüntü oranı, bitki örtüsü indeksi farklılığı, değişiklik vektörü analizi (CVA) ve arka plan çıkarma bulunur. Bu algoritmalar ortak bir özelliğe sahiptir, yani değiştirilen alanları belirlemek için eşikleri seçmek gerekir. Bu yöntemler değişiklik vektör analizi hariç nispeten basit, anlaşılır, uygulanması ve yorumlanması kolaydır ancak bunlar değişiklik bilgilerinin tam matrislerini sağlayamazlar. CVA görüntü farklılıklarının kavramsal bir uzantısıdır. Bu yaklaşım tanımlanan eşiklerden daha büyük olan tüm değişiklikleri tespit edebilir ve ayrıntılı değişiklik bilgileri sağlayabilir.

Görüntülerde yapılan aritmetik çıkarma işlemi tarihsel olarak farklı zamanlarda çekilmiş iki görüntünün piksel değerlerinin birbirinden çıkartılmasıyla yapılmaktadır [Fung and LeDrew,1988], [Tarhan, 2007]. Formül 3.1’de işlemin tanımı gösterilmiştir.

$$G_{ij}(k) = G_{ij}(1) - G_{ij}(2) + k \quad (3.1)$$

Burada:

- G_{ij} : Değişim tespiti yapılmış i satır, j sütundan oluşan görüntü,
- $G_{ij}(1)$: Birinci tarihteki i satır, j sütundan oluşan görüntü,
- $G_{ij}(2)$: İkinci tarihteki i satır, j sütundan oluşan görüntü,
- k : Piksel değerlerini negatif olmamasını sağlayan sabit değerdir.

Görüntülerde oranlama işlemi aritmetik bir işlemdir. İki farklı tarihteki görüntünün birbirine bölünerek oranlanmasıyla yapılmaktadır. Formül 3.2’de işlemin tanımı gösterilmiştir. Bu işlemin sonucunda oluşan piksel değerlerinin değişim tespitinde kullanılıp anlaşılması için histogramını gerip eşikleme yapılması gerekmektedir [Singh, 1989], [Tarhan, 2007]. Formül 3.2’de gösterim yapılmıştır.

$$GGGGGG = GGGGG(1)/GGGGG(2) \quad (3.2)$$

Burada:

- G_{ij} d: Değişim tespiti yapılmış i satır, j sütundan oluşan görüntü,
- $G_{ij}(1)$: Birinci tarihteki i satır, j sütundan oluşan görüntü,
- $G_{ij}(2)$: İkinci tarihteki i satır, j sütundan oluşan görüntüdür.

Cebir farkların bir dezavantajı değiştirilen alanları tanımlamak için uygun eşikleri seçme zorluğudur. Bu kategoride değişiklik tespit sonuçları için iki husus kritik öneme sahiptir. Uygun görüntü bantları veya bitki örtüsü endeksleri ve değiştirilen alanları tanımlamak için uygun eşikleri seçmedir. Çıkan görüntünün piksel değerleri 0 ila 1 arasındadır. Formül 3.3’te tanımı yapılmıştır.

$$GGGGGGGG = (GGGGGG - GGGGGGG)/ = (GGGGGG + GGGGGGG) \quad (3.3)$$

Burada:

- G_{ndvi} : Normalize Fark Bitki İndeksi görüntü,
- G_{nir} : Görüntünün NIR bandı,
- G_{red} : Görüntünün Red bandıdır.

3.2. Görüntülerin Dönüşüm Yöntemleriyle Değişim Tespiti

Dönüşüm kategorisinde Principal Component Analysis (PCA), Tasselled cap (KT), Gramm-Schmidt ve Ki-Kare dönüşümlerini içermektedir. Temel Bileşenler Analizi (PCA) en büyük değişikliğin olduğu yerleri ön plana çıkarmayı sağlayan bir dizi değişken azaltmayı amaçlayan yöntemdir [Gomez et al.,2007]. Bu yöntemlerin bir avantajı bantlar arasındaki veri fazlalığını azaltmak ve türetilmiş bileşenlerde farklı

bilgiler vurgulamaktadır. Bununla birlikte ayrıntılı deęişiklik matrisleri sağlayamazlar ve deęişen alanları tanımlamak için eşiklerin seğıilmesini gerektirirler. Dięer bir dezavantaj dönüştürülen görüntüler üzerindeki deęişim bilgisini yorumlama ve etiketlemedeki zorluktur.

3.3. Görüntülerin Görsel Analiziyle Deęişim Tespiti

Görsel olarak yorumlama insan gözüyle ton, doku ve şekilleri bir görüntüyle dięerini karşılaştırmada örüntüleri incelemesiyle olmaktadır [Tarhan,2007]. Görsel analizle deęişim teknięi çoklu zamansal görüntü kompozitinin görsel yorumunu ve deęişen alanların ekran üzerinde sayısallaştırılmasını içermektedir. Bu yöntem bir analistin deneyim ve bilgisinden tam olarak faydalanabilir. Görüntülerin doku, şekil, boyut ve kalıpları görsel yorumlama yoluyla arazi kullanımı/razi örtüsü (LULC) deęişiminin tanımlanmasında yararlı olan kilit unsurlardır. Bu elementler, dijital elementlerin tespit edilmesindeki zorluklardan dolayı dijital deęişim tespit analizlerinde sıklıkla kullanılmaktadır. Bununla birlikte, görsel yorumlamada yetenekli bir analist, LULC deęişikliği ile ilgili kararların alınmasına yardımcı olmak için tüm unsurları dahil edebilir. Bu yöntemin dezavantajı geniş alanlı bir deęişiklik tespit uygulamasında harcanan zamanın deęişmesidir ve deęişiklik tespit sonuçlarının zamanında güncellenmesi zordur.

3.4. Görüntülerin Sınıflandırılmasıyla Deęişim Tespiti

Sınıflandırma kategorisinde sınıflandırma sonrası karşılaştırma, spektral-zamansal karma analiz, beklenti maksimizasyon algoritması (EM) deęişim tespiti, denetimsiz deęişim tespiti, hibrit deęişim tespiti ve yapay sinir ağlarını (ANN) içermektedir. Bu yöntemler, iyi kalite sınıflandırma sonuçları elde etmek için eğitim örneęi verilerinin nitelięinin ve miktarının çok önemli olduęu sınıflandırılmış görüntülere dayanmaktadır. Deęişiklik bilgisi matrisi sağlama ve çoklu zamansal görüntüler arasındaki atmosferik ve çevresel farklılıklardan dış etkiyi azaltma kabiliyeti bu yöntemlerin en büyük avantajlarıdır. Bununla birlikte görüntü sınıflandırması için yüksek kaliteli ve yeterince sayıda eğitim örneęi setinin seğıilmesi, özellikle tarihsel görüntü verileri sınıflandırması için genellikle zordur. Son derece

hassas sınıflandırmalar üretmek için zaman harcayan ve zor olan görev, özellikle yüksek kaliteli eğitim numunesi verileri olmadığında çoğu zaman yetersiz değişim tespiti sonuçlarına yol açar [Lu et al.,2004].

3.4.1. Piksel Tabanlı Değişim Tespiti

Uzaktan algılama verilerinin ilk kullanımından bu yana görüntü analizinin ve değişim tespiti tekniklerinin temel birimi bir pikseldir. Bir görüntü pikseli, spektral özellikleri algılamak ve ölçmek için kullanılan bir analitik birimdir [Hussain et al.,2013].

Piksel tabanlı sınıflandırma ile değişim tespiti tekniklerini 15 kategoride toplanmıştır.

Görüntü farkının alınması, değişiklikleri temsil etmek, bir görüntü üretmek için kesin olarak birlikte kaydedilmiş çok zamanlı iki görüntü kullanılır. İki görüntü arasındaki fark, doğrudan pikselin radyometrik değerlerinden veya doku veya bitki indeksleri gibi çıkarılan/türetilen/dönüştürülmüş görüntülerde ölçülebilir. Görüntü farklılaştırmanın avantajı basit ve sonuçları yorumlamak kolaydır. Fark görüntüsü matematiksel olarak Formül 3.4’de gösterim yapılmıştır.

$$I_d(x, y) = I_1(x, y) - I_2(x, y) \quad (3.4)$$

Burada I_1 ve I_2 , t_1 ve t_2 zamanından görüntülerdir ve (x,y) koordinatlardır ve I_d ise fark görüntüsüdür. Parlaklığında değişiklik olmayan pikseller ortalama etrafında dağılırlar [Lu et al.,2004]. Değişim her iki yönde olabileceğinden, hangi görüntünün hangisinden çıkarılacağına karar vermek araştırmacının sorumluluğundadır [Gao,2009].

Görüntü oranlaması, iki görüntü arasındaki oran hesaplanır. Görüntü oranlamasının avantajı kalibrasyon yani güneş açısı, gölge ve topografya etkisi dahil hataları daha iyi ele alır [Rignot and Van Zyl,1993]. Matematiksel olarak Formül 3.5’de gösterim yapılmıştır.

$$I_r = I_1(x,y) / I_2(x,y) \quad (3.5)$$

Görüntü farklılaştırmadan farklı olarak, değişim sonuçları oranlarla ifade edildiğinden görüntülerin bölme işlemindeki sırası önemli değildir ve değişmeyen alanlar teorik olarak 1 değerinde olmalıdır [Hussain et al.,2013].

Görüntü regresyonu zamandan (t_2) görüntü I_2 'nin zamandan (t_1) gelen görüntü I_1 'in doğrusal bir fonksiyonu olduğu varsayılır. I_2 resmi "referans" resim olarak ve I_1 "konu" resmi olarak alınır. Özne görüntüsü daha sonra referans görüntünün radyometrik koşullarına uyacak şekilde ayarlanır. En küçük kareler regresyonu gibi bir regresyon analizi, özne görüntüsünü referans görüntüyle eşleştirecek şekilde radyometrik olarak normalleştirerek kazançları ve ofsetleri belirlemeye yardımcı olabilir [Lunetta,1999]. Değişim (I_d), ilk tarihli görüntüden regresyona uğramış görüntünün çıkarılmasıyla saptanır. Matematiksel olarak Formül 3.6'da gösterim yapılmıştır.

$$\begin{aligned}\hat{I}_d(x,y) &= \alpha I_d(x,y) + b \\ I_d(x,y) &= I_d(x,y) - \hat{I}_d(x,y)\end{aligned}\tag{3.6}$$

Görüntü regresyonunun avantajı farklı tarihler için alınan görüntülerde piksel değerleri arasındaki ortalama ve varyanstaki farklılıkları hesaba katar ve bu sebeple atmosferik koşullar ve güneş açılarından kaynaklanan olumsuz etkileri azaltır [Singh,1989].

Vejetasyon indeksi farkı, bitki örtüsünün multispektral moddaki gözlemler üzerindeki etkisini değerlendirmek için tasarlanmış matematiksel dönüşümlerdir. Bu indeksler kırmızı banttaki güçlü bitki örtüsü absorbanı ve yakın kızılötesi bantta güçlü yansıma temelinde spektral farklılıkları geliştirir. Değişim tespiti için genellikle vejetasyon indeksleri iki görüntü için ayrı ayrı üretilir ve daha sonra standart piksel tabanlı değişim tespiti (örneğin, fark alma veya oranlama) uygulanır [Hussain et al.,2013]. Farklı bitki endeksleri geliştirilmiştir. Bunlar (a) Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI) ve Oranlı Bitki Örtüsü İndeksi (RVI) dahil orana dayalı, (b) Dikey Bitki Örtüsü İndeksi (PVI) ve Fark Bitki Örtüsü İndeksi dahil ortogonal indeksler (DVI) ve (c) Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI) ve değiştirilmiş toprak ayarlı bitki örtüsü indeksi (MSAVI) [Chen vd.,1999]. Matematiksel olarak Formülleri 3.7'de gösterilmiştir.

$$\begin{aligned}
RVI &= \frac{nn}{rr} \\
NDVI &= \frac{(nn-rr)}{nn+rr} \\
TVI &= \frac{(gg-rr)}{(gg+rr)} + 0.5 \\
SAVI &= \frac{(gg-rr)}{(gg+rr+ll)} (1+ll) \\
MSVI &= \frac{2nn+1 - \sqrt{(2nn+1)^2 - 8(nn-rr)}}{2}
\end{aligned} \tag{3.7}$$

Burada n kıvılotesi banta yakındır ve r kırmızı banttır. SAVI'deki L, NDVI ve SAVI arasındaki aynı bağı onaylar. Vejetasyon indeks farkının avantajı topografik etkilerin ve aydınlatmanın etkilerini azaltır.

Değişim vektör analizi, değişim tespiti için çoklu görüntü bantlarının eş zamanlı analizine izin verir. CVA'nın amacı, zaman içinde farklı değerlere sahip belirli bir pikselin, özellik uzayında önemli ölçüde farklı bir yerde bulunmasıdır [Jensen,2005]. Piksel değerleri, spektral bantların vektörleri olarak ele alınır ve farklı zamanlardaki bütün pikseller için vektörlerin çıkarılmasıyla değişim vektörü (CV) hesaplanır [Malila,1980]. Değişim tespitinin yönü, değişikliğin büyüklüğünün değişim tespitinin uzunluğuna karşılık geldiği değişimin türünü gösterir. CVA, dönüştürülmüş veriler üzerinde de gerçekleştirilebilir. Değişim vektör analizinin avantajları, istenilen sayıda spektral bant işlenebilir ve detaylı değişim tespiti bilgileri üretebilir.

Temel bileşen analizi (PCA), verileri ilişkisiz bir kümeye aktarmak için kovaryans matrisini veya korelasyon matrisini kullanır. Elde edilen matrislerin, birinci ana bileşenin (PC) veri varyasyonunun çoğunu ifade ettiği yerde azalan düzende sıralanır. Sonraki bileşen, sonraki en büyük varyasyon miktarını tanımlar ve önceki ana bileşenden bağımsızdır. Matematiksel olarak "Ana Eksen Dönüşümü" ne dayanan PCA, çok değişkenli verilerin yeni bir bileşen kümesine dönüştürülmesi ve veri fazlalığını azaltmasıdır [Lillesand et al.,2008]. İki PCA tabanlı değişim tespiti yaklaşımı kullanılır. Birincisi, ayrı döndürme, görüntülerden ayrı ayrı PC'ler elde etmek ve daha sonra diğer değişim tespiti tekniğini (görüntü farklılaştırma gibi) kullanmaktır. İkincisi, iki zamanlı görüntülerin tek bir kümede birleştirildiği ve PC uygulanır. İki zamanlı verilerle negatif korelasyona sahip PC'ler değişime karşılık gelir. Temel bileşen analizinin avantajları, veri fazlalığı azaltma ve türetilmiş bileşenlerde farklı bilgileri vurgular.

Kauth-Thomas Dönüşümü (KIT)/Tasseled Cap dönüşümü, çok bantlı ve çok tarihli bir veri setinin doğrusal dönüşümüdür ve sabit olması açısından PCA'dan farklıdır. Bu çıkış özellikleri, yeşillik parlaklığını ve ıslaklığı temsil eder. Kauth ve Thomas (1976) tarafından sunulan, olay sınıflarının belirli bir karakteristiğinin bir fonksiyonu olan spektral verilerin yapısını analiz eder. Değişim; parlaklık, yeşillik ve ıslaklık değerlerine göre ölçülür [Lu et al.,2004]. Gram-Schmidt (GS), KT parlaklık, yeşillik ve ıslaklığın çok zamanlı analoglarına karşılık gelen tablo bileşenleri ve bir değişim bileşeni üreten çok zamanlı verileri işlemek için KT'yi değiştirerek geliştirilmiştir [Collins and Woodcock,1994]. Tasseled cap dönüşümünün avantajı, veri fazlalığını azaltma, olaydan bağımsız ve uzun vadeli çalışma için temel spektral bilgilerin geliştirilmesine izin veren kararlı spektral bileşenler üretir.

Sınıflandırma sonrası karşılaştırma, iki zamanlı görüntüler ilk önce düzeltilir ve sınıflandırılır. Sınıflandırılmış görüntüler daha sonra değişiklikleri ölçmek için karşılaştırılır. Bire bir karşılaştırma yapabilmek için her iki görüntünün sınıfları aynı olmalıdır. Bireysel görüntü sınıflandırmasından kaynaklanan hatalar, son değişiklik haritasında yayılır ve son değişim tespiti doğruluğunu azaltır. Bu yaklaşım en belirgin nicel değişim tespiti yöntemidir çünkü değişimden değişime bilgi sağlar [Bouziani et al.,2010; Im and Jensen,2005; Jensen,2005]. Bu yaklaşımda değişim tespiti sonuçlarını iyileştirmek için, tek tek görüntülerin sınıflandırılması mümkün olduğunca doğru olmalıdır. Sınıflandırma sonrası karşılaştırma tekniğinin avantajları, atmosferik, sensör ve çevresel etki azaltır ve ayrıca çoklu sensör görüntüleri kullanmanın etkisini en aza indirir.

Birleşik veya doğrudan çok tarihli sınıflandırma tekniği, çok tarihli veri kümeleri için tek bir analizin gerçekleştirildiği arazi kullanımı ve arazi örtüsü değişim haritaları oluşturmaya yönelik en eski yarı otomatik yaklaşımlar arasındadır [Lunetta,1999]. Çoklu zamansal ve düzeltilmiş görüntüler ilk önce birlikte yığılır [Hussain et al.,2013]. PCA'daki küçük bileşenler, spektral kontrastı artırma ve değişiklikleri temsil etme eğilimindedir [Collins and Woodcock,1996]. Bu tekniğin avantajları, yığılmış veriler için bir sınıflandırma ve atmosferik düzeltme gerekli değildir.

Diğer gelişmiş yöntemlerden bazıları; yapay sinir ağları, destek vektör makineleri ve karar ağacı algoritmalarıdır [Hussain et al.,2013]. Görüntü tabanlı değişim tespiti için yapay sinir ağları (ANN) algoritmaları, sınıflandırma tabanlı değişim tespiti kategorisine aittir. Yapay sinir ağları algoritmaları parametrik değildir

ve veri dağıtımı ve bağımsızlığı hakkında herhangi bir varsayımda bulunmaz. Çıktıların girdilere nasıl bağlı olduğunu matematiksel olarak belirtmeden, sürekli fonksiyonları verilerden uyarlayarak tahmin ederler [Im and Jensen,2005]. Yapay sinir ağları algoritması, eğitim veri kümesinden öğrenir ve görüntü ile değişiklikler arasında ağlar kurar. Eğitilen ağ daha sonra bir değişim haritası oluşturmak için ana veri kümesine uygulanır [Dai and Khorram,1999; Gopal and Woodcock,1996]. Bu yaklaşımı, arazi örtüsü sınıfları normal dağılmadığında daha iyi değişim tespiti sonuçları sağlayabilir [Lu et al.,2004]. Bu yaklaşımın avantajları, eğitim verilerine dayalı olarak veri özelliklerini tahmin eder ve yapay sinir ağları parametrik olmayan denetimli algoritmadır. Destek Vektör Makinesi (SVM), denetimli bir parametrik olmayan istatistiksel öğrenme tekniğidir ve temel alınan veri dağılımı hakkında hiçbir varsayımda bulunmaz [Hussain et al.,2013]. Destek vektör makineleri, sınıflandırma için yapısal risk minimizasyonunu uygulayan istatistiksel öğrenme teorisine dayanmaktadır [Vapnik,2000]. Yığılmış çok zamanlı görüntülere uygulandığında, değişiklik ve değişiklik olmayan ikili sınıflandırma problemi olarak ele alınır [Huang et al.,2008]. Algoritma, eğitim verilerinden öğrenir ve değişikliği, değişiklik olmayandan sınıflandırmak için spektral özelliklerden otomatik olarak bir eşik değeri bulur [Bovolo et al.,2008]. Bu yaklaşımın avantajları, parametrik olmayan ve veri dağıtımında varsayım yoktur, küçük eğitim veri setlerini işleyebilir ve genellikle geleneksel yöntemlerden daha yüksek sınıflandırma doğruluğu üretir [Mantero et al.,2005] ve teorik olarak daha büyük veri kümelerini daha yüksek boyutlulukla işleyebilir ve özellikle hiperspektral görüntü sınıflandırması için kullanılır [Melgani and Bruzzone,2004]. Karar ağacı (DT) sınıflandırma algoritmaları da veri dağıtımı ve bağımsızlığı hakkında hiçbir varsayım olmaksızın parametrik değildir. Bu karar ağacı algoritmaları, her düğümün bir dizi öznelik değeri üzerinde bir testi temsil ettiği, her dalın testin bir sonucunu temsil ettiği ve ağaç yapraklarının sınıfları veya sınıf dağılımını temsil ettiği, akış şeması benzeri bir ağaç (hiyerarşik) yapısı oluşturur [Han et al.,2011; Larose,2005]. Karar ağacı düğümündeki sınıflandırma kuralları, nitelik değerlerinin analizine dayanmaktadır. Bir karar ağacı oluşturulduktan sonra, bilinmeyen durumları sınıflandırmak için kullanılabilir. Değişiklik olan ve değişiklik olmayan ikili sınıflandırma problemi olarak ele alınabilir veya değişiklikleri ölçmek için sınıflandırma sonrası karşılaştırma yapılabilir. Sınıflandırma ve değişiklik izleme için kullanılan diğer bazı makine öğrenimi algoritmaları arasında; genetik programlama [Makkeasorn et al.,2009], rastgele orman [Pal,2005; Sesnie et al.,2008;

Smith,2010] ve Hücresel otomata [Yang et al.,2008]. Bu yaklaşımın avantajları, parametrik olmayan ve veri dağıtımında varsayım yok ve değişiklik ve değişiklik olmayan sınıflar için kural seti sağlayabilir.

Coğrafi Bilgi Sistemi tabanlı teknikte, mevcut görüntü işleme sistemlerinin çoğu, CBS ile genellikle entegredir ya da uyumludur. CBS, verilerin entegrasyonu, görselleştirilmesi, analizi ve harita üretimi için bir temel sağlar. CBS verileri bir görüntünün üzerine bindirmek için kullanılabildiğinden, veri akışı çift yönlü olabilir; alternatif olarak, görüntü analizinden elde edilen sonuçlar ve CBS verilerini güncellemek için kullanılabilir. Benzer şekilde, görüntü verileri CBS veri tabanını güncellemek için de kullanılabilir. CBS ayrıca karşılaştırma ve değişim tespiti için geçmiş ve güncel haritaların entegre edilmesini sağlar. Bu gibi durumlarda, görüntü bindirme ve ikili maskeleye, her sınıftaki değişim dinamiğini nicel olarak ortaya çıkarmaya yardımcı olabilir. CBS'nin uzaktan algılama entegrasyonu ile uygulanabilirliği, nesne tabanlı görüntü analiz tekniklerinin daha sık kullanılmasıyla geliştirilmiştir. CBS veri tabanında depolanan nesneler hakkındaki uzamsal ve uzaysal bilgiler, diğer görüntü analizleriyle birlikte değişim tespiti için uzaktan algılama görüntülerinden çıkarılan nesnelere bağlandığında önemli bir rol oynayabilir [Bouziani et al.,2010]. CBS entegrasyonunun avantajı, CBS veri tabanının güncellenmesini ve görüntü yorumlama ve analizine yardımcı olmak için CBS'den yardımcı verilere erişmeye izin verir.

Doku analizine dayalı değişiklik tespiti, görüntülerdeki doku özellikleri ölçülür ve değişim tespiti için karşılaştırılır. Doku, nesnelerin yapısal düzenlemeleri ve yerel komşuluklarına göre ilişkileri hakkında bilgi sağlar [Caridade et al.,2008]. Değişim, görüntülerden dokusal değerlerin karşılaştırılmasıyla ölçülür. Birkaç doku ölçüm algoritması arasında, ikinci dereceden bir istatistik olan gri seviyeli bir birlikte oluşum matrisi (GLCM) ortaktır [Haralick et al.,1973; Sali and Wolfson,1992]. GLCM, gri değerlerin spektral ve uzaysal dağılımını inceler. Piksel başına karşılaştırma yerine, görüntü normalde daha küçük pencerelere bölünür; doku hesaplanır ve pencere düzeyinde karşılaştırma yapılır.

Spektral karışım analizi (SMA), yüksek spektral çözünürlük nedeniyle artan boyutluluğu ele almak için kullanılmıştır. SMA'daki varsayım, multispektral görüntü piksellerinin, daha sonra bir sahnedeki yüzey bileşenleri ile ilgili olabilecek saf spektral bileşenlerin alt piksel oranları açısından tanımlanabilmesidir [Hussain et al.,2013]. Basit bir durumda, lineer karışım modeli, saf örtü tipinin göstergesi olan

spektral tepkiye sahip sahne elemanı yani uç eleman spektrumları, her bir uç elemanın toprak örtüsü yüzdesi tarafından ağırlıklandırılır ve doğrusal olarak birleştirilir [Versluis and Rogan,2009]. Matematiksel olarak Formül 3.8’de gösterilmiştir.

$$GG_{ii} = \sum_{jj=1}^m aa_{ijj}ff_{jj} + ee_{ii} \quad (3.8)$$

Burada:

- $ii = i$ spektral bandında belirli bir pikselin ölçülen yansıması,
- n , karışım bileşenlerinin sayısıdır,
- ff_{jj} , j son üyesinin GG_{ii} cinsinden alan oranı veya kesridir,
- aa_{ijj} , j uç elemanının i spektral bandındaki yansımasıdır,
- GG_{ii} artık, gözlemlenen (ii) ve modellenen piksel değerleri

arasındaki farktır [Versluis and Rogan,2009].

Bulanık değişiklik algılama tekniğinde bulanıklığa değinilir. Bulanıklık, sınıf etiketlemenin belirsizliği ile ilgilenir ve farklı sınıflar ve fenomenler arasındaki sınırların bulanık olduğunu ve bir sınıf içinde belki de fiziksel farklılıklardan dolayı heterojenlik olduğunu söyler [Lizarazo and Joana,2010]. Bu, değişikliği değişiklik olmamasından ayırt etmek için değerli bir eşik seçmede zorluk olduğunda önem kazanır. Bulanık akıl yürütmenin sonuçları kesikli ve net değildir, daha ziyade “olasılıklar” cinsinden ifade edilir [Metternicht,1999]. Yalnızca kısmi üyelik derecesine sahip öğeler içerebilir. Bulanık küme, bir üyelik fonksiyonu yani üyelik derecesi tarafından tanımlandığından ve en yüksek olasılığa sahip sınıf gerçek sınıf olarak yorumlandığından, bulanık üyelik olasılıksal yorumdan farklıdır [Hussain et al.,2013]. Bu tekniğin avantajları, objektif olarak eşiği tanımlar ve olasılıklı bir sınıf üyeliğine izin vermek, geleneksel bir "zor" sınıflandırmadan daha uygun bir temsil sağlayabilir.

Değişiklik tespiti için çok sensörlü veri birleştirmede çeşitli uzamsal, spektral ve zamansal çözünürlüklerde uzaktan algılama verilerinin alınması, farklı çözünürlüklerde veri alınmasına izin veren bir görüntü piramidi formüle eder. Farklı sensörlerden gelen veriler, arazinin belirli yönlerini yansıtır ve farklı sensörlerden gelen verilerin kullanılması, belirli özelliklerin belirlenmesine yardımcı olabilir. Farklı sensörlerle çalışmak çok da kusursuz olmasa da özellikle zaman serisi analizi

yapıldığında ve sensörlerden birinin kullanılmadığı durumlarda bazen yararlıdır [Serra et al.,2003]. Multispektral uzaktan algılama verileri, özellikle kentsel alanlarda heterojen arazi kullanımları ve üç boyutlu yapılarla uğraşırken de faydalıdır [Griffiths et al.,2010; Richards,2005]. Düşük ve yüksek çözünürlüklü görüntüler arasındaki spektral kapsam farkı, karışıklıklara neden olur. Değişik tespiti için çoklu sensör verilerini birleştirirken, uygun işleme yöntemlerini seçmek ve elde edilen verileri muhakeme etmek için giriş verilerinin fiziksel özelliklerinin anlaşılması gerekir. Farklı piksel boyutu sınıflandırma sonuçlarını etkiler. Daha düşük çözünürlüklü görüntünün sınıflandırılması, çok yüksek çözünürlüklü görüntülerinde görünen bazı öğeleri eksik kalmaktadır. Piksel boyutu ve/veya grid orijini, görüntüler değişim tespiti için bindirildiğinde de geometrik hatalara neden olur. Bu tekniğin avantajları, farklı nesneleri algılamak için farklı sensörlerden yararlanmaya izin verir ve sensörlerden biri mevcut olmadığında zaman serisi analizinde yardımcı olur.

3.4.2. Nesne Tabanlı Değişim Tespiti

Nesne tabanlı değişim tespiti, geleneksel piksel tabanlı yaklaşımın yerine görüntüdeki piksel gruplarını yani görüntü nesnelerini anlamlı coğrafi varlıkları modellemek için kullanır ve bu görüntü nesneleri arasındaki farklılıkları tespit eder [Blaschke,2010]. Nesne tabanlı değişim tespiti görüntü nesnelerindeki uzamsal, spektral ve coğrafi bilgileri birleştirir [Chen et al.,2012]. Nesne tabanlı değişim tespiti, uzaktan algılama teknolojisi ile elde edilen görüntülerden, çalışma alanındaki bir yerin görüntü nesnelerinin öncesi ve sonrası arasındaki karşılaştırmaya göre yapılması esastır [Jovanović et al.,2015]. Nesne tabanlı değişim tespiti [Stow, 2010] tarafından iki grupta özetlenmiştir: sınıflandırma sonrası karşılaştırma ve çok zamanlı görüntü objesi analizidir. [Chen et al., 2012], tarafından bu yöntem dört grupta özetlenmiştir: görüntü-obje, sınıf-obje, çok zamanlı obje ve hibrit değişim tespitidir.

Görüntü-obje değişikliği analizi, bu yöntemde görüntülere bir eşik uygulayarak görüntü nesnelerini karşılaştırılmasıdır. Bu şekilde piksel tabanlı değişiklik analizine benzerlik göstermektedir [Chen et al.,2012]. Farklı tarihlerde alınan görüntülerde bu analiz yönteminin uygulanabilmesi için, görüntü nesnelerinin çıkarılan özellikleri, geometrik ve spektral bilgilerin karşılaştırılması gerekmektedir [Lefebvre et al.,2008; Hall and Hay,2003]. Bu yöntemde iki strateji uygulanmaktadır. [Miller et al., 2005],

zamansal olarak ilk alınan görüntüden nesneler çıkartılıp bölütleme işlemi yapılmadan tarih olarak ikinci alınan görüntüde nesneler aranır. İkinci strateji olarak ise [Niemeyer et al., 2008], farklı zamanlarda alınan görüntülerde görüntü nesneleri çıkartılıp değişim tespiti için bu çıkartılan nesneler karşılaştırılır. Bu yöntemde; nesnelerin doğrudan karşılaştırılması, uygulamanın zor olmayışı, spektral veya çıkarılan özelliklere göre değişikliklerin yapılması ve coğrafi bilgi sistemlerine kolaylıkla uyum sağlaması görüntü-nesne değişikliği analizinin avantajları olarak söylenebilir [Hussain et al.,2013].

Sınıf nesnesi değişikliği algılama, en yaygın olarak kullanılan nesne tabanlı değişiklik tespiti metodolojisi olup, başlangıçtan itibaren değişiklikleri gösteren bir değişiklik matrisi oluşturulmasına izin verir [Hussain et al.,2013]. Bu yöntemde ayrıntılı bir değişiklik analizi için sınıflandırılan nesneler karşılaştırılır. Değişikliği tespit etmek ve tanımlamak için çok zamanlı nesnelerin karşılaştırılması amacıyla sınıflandırma sonrası karşılaştırmaya dayanan teorik bir nesne tabanlı değişiklik tespiti sağlanmıştır [Blaschke,2005]. Nesne tabanlı değişiklik tespitinde kullanılan sınıflandırma algoritmaları hem görsel bilgiyi hem de doku gibi türetilmiş faktörleri içerir. Sınıf nesnesi değişiklik tespitinin performansı, piksel tabanlı yaklaşıma benzer şekilde, sınıflandırma algoritmasının performansı ve doğruluğu ile güçlü bir şekilde ilişkilidir. Bu yaklaşımın avantajı, mevcut tüm nesneler, nesne tabanlı değişiklik tespitinde kullanılabilir, tematik, geometrik ve topolojik değişim ölçümüne izin verir ve sınıflandırma karşılaştırmasına dayalı değişiklik sağlar.

Çok zamanlı nesne değişikliği algılama, birleştirilmiş görüntülere doğrudan uygulanır. [Hussain et al.,2013]. Farklı tarihlerde elde edilen görüntüler nadiren de olsa istenen görüş açısı, aydınlatma ve meteorolojik şartlar ile çalışma yapılacak bölgeler aynı şekilde görüntülenir [Wulder et al.,2008]. Bu sebeple, farklı zamanlardan bölütleme ile oluşturulan görüntü nesneleri, aynı özellikleri belirtmelerine rağmen, çoğunlukla geometrik olarak değişir. Farklı zamanlarda elde edilen görüntüler tarih sıralarına göre birleştirilir. Birleştirildikten sonra oluşan görüntü segmente edilir ve değişim nesneleri üretilir. Çok zamanlı nesne değişikliği algılama ile farklı zamanlarda elde edilen birçok görüntüleri ayrı ayrı segmente etmek yerine, tek bir segmentasyon sonucu ile çalışma yapılacak bölgelerdeki görüntü nesnelerinin bütün niteliklerinden yararlanılır [Chen et al.,2012]. Bu yaklaşımın avantajları, birleştirilmiş görüntülere bir kere segmentasyon uygulanır, görüntü objeleri iki kere aynı geometrik niteliklere sahip

olması ve geometrik, spektral ve türetilmiş niteliklerden faydalanarak değişim eğrileri oluşturulur [Hussain et al.,2013].

Hibrit değişiklik algılama, diğer algoritmalarından farklı olarak hem nesne hem de piksel tabanlı yöntemlerin kullanımını içeren algoritmalar. Hibrit değişiklik algılama yaygın olarak kullanılan bir yöntemdir. Hibrit değişim algılama yönteminde ilk önce görüntüdeki piksellerden değişiklik bilgisini üretir ve elde edilen değişiklik sonuçlarını daha iyi sağlamak için nesne tabanlı yöntemin daha sonra uygulanması gerekmektedir [Chen et al.,2012]. Jianyaa et al. (2008) hibrit değişiklik tespitini iki şekilde gruplandırmıştır: yöntem tabanlı ve sonuç tabanlıdır. Hibrit değişiklik tespiti yöntemleri, eşik ve sınıflandırma tabanlı değişiklik tespiti yöntemlerinin avantajlarını birleştirebilir [Lu et al.,2004]. McDermid et al. (2008), piksel ve nesne tabanlı şemaları birleştiren hibrit algoritmalar, nesnelerin tutarsız betimlenmesinden kaynaklanan küçük ve doğal olmayan değişikliklerin yanı sıra gürültü değişikliklerini de başarıyla azaltılmasını sundu. Hibrit değişiklik tespitinde birden fazla işlem adımı yer aldığından, kesin değişiklik sonuçlarının piksel ve nesne tabanlı yöntemlerin farklı birleşimlerinden nasıl etkilendiği belirsizliğini korumaktadır [Chen et al.,2012].

4. UYGULAMA ve SONUÇLAR

4.1. Uygulama Alanı ve Veri

Tez kapsamında klasik piksel tabanlı değişim analizi yerine nesne tabanlı değişim analizi yardımıyla arazi örtüsü/arazi kullanımının tespiti problemi ele alınmıştır. Arazi örtüsü ve arazi kullanımı değişikliklerinin tespiti için Yalova ve Rize şehirleri içerisinde kalan iki farklı çalışma alanı belirlenmiştir.

Yalova Türkiye'nin kuzeybatısında ve Marmara bölgesinin güneydoğusunda yer almaktadır. Şehrin kuzeyinde ve batısında Marmara Denizi, güneyinde Bursa ve Gemlik Körfezi ve doğusunda ise Kocaeli bulunmaktadır. Türkiye'nin en küçük ili olan Yalova'nın yüzölçümü 833 km²'lik bir alandır. Yalova 39-40° kuzey enlemi, 29-61° doğu boylamları arasında yer alır.

Rize Türkiye'nin kuzeydoğusunda yer almaktadır. Rize ilinin kuzeyinde Karadeniz, batısında Trabzon, doğusunda Artvin ve Güneyinde Erzurum ve Bayburt bulunmaktadır. Türkiye'nin yetmiş ikinci ili olan Rize 3920 km²'lik yüzölçümüne sahiptir. Rize 40° -22' ve 41°-28' doğu meridyenleri ile 40°-20' ve 41°-20' kuzey paralelleri arasında yer alır. Rize ve Yalova'daki çalışma alanları Şekil 4.1'de gösterilmiştir.



Şekil 4.1: Çalışma Alanları.

Çalışmada kullanılan uydu görüntülerinin tamamı Sentinel-2A uydusundan elde edilmiştir. Sentinel-2A uydusunun konumsal çözünürlüğü spektral bantlarına göre değişmekte olup 10,20 ve 60 m çözünürlüğe sahiptir. Radyometrik çözünürlüğü ise 12 bittir. Bu uydu başlangıç noktasına her 5 günde bir ulaşarak tam bir tur tamamlamaktadır. Aynı sensörden elde edilmiş görüntülerin seçimine dikkat edilmiştir. Bu uydu görüntülerine ilişkin bilgiler Tablo 4.1’de verilmektedir. Çalışmada mekânsal çözünürlüğü 10m olan mavi, yeşil ve kırmızı bantlar kullanıldı.

Tablo 4.1: Sentinel 2A görüntüsünün spektral bantları.

Bant	Merkezi dalga boyu (nm)	Bant genişliği (nm)	Mekânsal çözünürlük (m)
Bant 1- Kıyı Aerosolü	442.7	21	60
Bant 2- Mavi	492.4	66	10
Bant 3- Yeşil	559.8	36	10
Bant 4- Kırmızı	664.6	31	10
Bant 5- Bitki örtüsü kırmızı kenar	704.1	15	20
Bant 6- Bitki örtüsü kırmızı kenar	740.5	15	20
Bant 7- Bitki örtüsü kırmızı kenar	782.8	20	20
Bant 8- Yakın Kızılötesi (NIR)	832.8	106	10
Bant 8a- Bitki örtüsü kırmızı kenar	864.7	21	20
Bant 9- Su buharı	945.1	20	60
Bant 10- Kısa dalga Kızılötesi (SWIR)	1373.5	31	60
Bant 11- Kısa dalga Kızılötesi (SWIR)	1613.7	91	20
Bant 12- Kısa dalga Kızılötesi (SWIR)	2202.4	175	20

Yalova ve Rize illerindeki çalışma bölgelerini kapsayan Sentinel-2A görüntülerin ESA OpenHub sitesinden (<https://scihub.copernicus.eu/>) temin edilmiştir. Yalova için kullanılan görüntüler 04.06.2016 ile 24.05.2022 tarihlerinde kaydedilmiş görüntülerdir. Rize ilindeki çalışma alanının görüntüleri 12.06.2016 ile 01.06.2022 tarihlerinde kaydedilmiştir.

4.2. Segmentasyon


Nesne tabanlı sınıflandırma yönteminde ilk işlem adımı segmentasyondur. Segmentasyon görüntü üzerinde aynı özelliklere sahip piksellerin gruplanması ve nesnelerin veya alanların oluşturulması işlemidir. Bu çalışmada ortalama kaydırma

(mean-shift) segmentasyonu ve çoklu çözünürlüklü (multi-resolution) segmentasyon işlemi kullanılmıştır. QGIS yazılımında ortalama kaydırma segmentasyonu kullanılmıştır. eCognition yazılımında çoklu çözünürlüklü segmentasyonu kullanılmıştır.

4.2.1. Ortalama Kaydırma (Mean-Shift) Segmentasyonu

Ortalama kaydırma segmentasyonu, görüntüdeki her bir noktaya filtre yinelenerek hareket ettirilir [Yang et al.,2003]. Bu segmentasyon görüntülerdeki gölgeleme veya renk uyumu farklılıklarını elimine ederek istenen ton farkı kadar küme merkezi belirlenir. Ortalama kaydırma segmentasyonu görüntüye uygulanırken, her bir küme merkezi için piksellerin ortalamaları hesaplanır. Daha sonra seçilen piksellerin küme merkezi olarak hesaplanan ortalamalarına göre eşit konumlara kaydırılır. Bu işlemler yakınsamaya kadar tekrarlanır ve seçilen pikseller en yakın olan küme merkezine birleştirilir. Her küme merkezi için, piksellerin değerleri ayrı ayrı toplanıp ortalaması alınır ve yeni küme merkezleri tespit edilmiş olur [Karlı vd.,2010].


Ortalama kayma, küçük nokta değişimlerinden etkilenmeyen parametrik olmayan bir kümeleme tekniğidir. Küme sayısı hakkında ön bilgi gerektirmeyen ve kümelerin şeklini kısıtlamayan güçlü bir denetimsiz veri analizi tekniğidir. Küme boyutunu dikkate alır ve eşik altındaki kümeleri oluşturmaz. QGIS yazılımında kullanılan yöntemin iş akış şeması Şekil 4.2’de gösterilmiştir.



Şekil 4.2: QGIS yazılımındaki iş akış şeması.


Bu çalışmada Rize'deki çalışma bölgesini içeren iki farklı tarihli Sentinel-2A görüntülerine QGIS yazılımında segmentasyon işlemi ayrı ayrı yapılmıştır. Rize'deki çalışma alanında sınıf değeri dört alınmıştır ve görüntüde dört sınıf oluşturulmuştur. Bu sınıflar boş alan, yapı, vejetasyon ve su alanlarıdır.

QGIS yazılımında segmentasyon yapılırken Rize ili 2016 yılı görüntüsü için uzaysal yarıçap 5, alan yarıçapı 15, mod yakınsama eşiği 0.10, maksimum yineleme sayısı 100, minimum bölge boyutu 10 ve sekiz komşu bağlantısı seçilmiştir. Şekil 4.3'de segmentasyon parametre seçimi arayüzü gösterilmiştir.



Şekil 4.3: Rize ili 2016 yılı görüntüsü segmentasyon parametre seçim arayüzü.

Seçilen parametreler sonucunda görüntü segmente edilmiş ve elde edilen segmentasyon görüntüsü Rize ili 2016 yılı için Şekil 4.4'te gösterilmiştir.



Şekil 4.4: Rize ili 2016 yılı ortalama kayma segmentasyon haritası.

Segmente edilmiş görüntüdeki segmentlere ilişkin metrik bilgiler Tablo 4.2’de gösterilmiştir. Görüntüde toplam 18160 segment oluşurken, minimum segment alanı 100.016 m² ve maksimum segment alanı 11820116.35 m² olarak hesaplanmıştır.

Tablo 4.2: Rize ili 2016 yılı ortalama kayma algoritması ile oluşturulan segmentlere ilişkin metrik bilgileri.

Rize	
2016	
Segment Sayısı	18160
Minimum Değer	1
Maksimum Değer	18253
Minimum Alan	100.016
Maksimum Alan	11820116
Ortalama değer	9091.53
Medyan değer	9080.5
Standart sapma	5258.38

Segmentasyon kalitesinin değerlendirilmesinde kontrollü yaklaşım kullanılmıştır. Literatürde en sık kullanılan kontrollü yaklaşımlardan Area Fit Index

(AFI) ve Quality Rate (Qr) metrikleri bu çalışmada ele alınmıştır. Bu metriklerde elle sayısallaştırılan referans alan (yer doğrulama verisi) ile segmentasyon sonucu elde edilen segment arasındaki fark alma, kesişim ve birleşim alanlarına dayanır (Clinton et al. 2010). Matematiksel olarak formülleri Formül 3.9’da gösterilmiştir.

$$AAAAAA = \frac{AA_{rr(ii)} - AA_{ss(jj)}}{AA_{rr(i)}}$$

$$QQGG = \frac{AA_{rr(ii)} \cap AA_{ss(jj)}}{AA_{rr(ii)} \cup AA_{ss(jj)}} \quad (3.9)$$

Burada: $AA_{rr(ii)}$, toplam referans alanı ve $AA_{ss(jj)}$, ele alınan segmentlerin toplam alanıdır.

Rize ili 2016 yılı görüntüsü içim AFI ve Qr metriklerini hesaplamak amacıyla öncelikli olarak bazı alanlar elle sayısallaştırıldı. 2016 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.5’de gösterilmiştir.



Şekil 4.5: Rize ili 2016 yılı segmentlerin referans nesnelerle örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam

alanları hesaplandı. Rize ili 2016 yılı ortalama segmentasyonu kalite metrikleri Tablo 4.3’de gösterilmiştir. AFI metriğinde sonucun sıfır olması mükemmel bir eşlemeyi ifade etmektedir. Pozitif AFI görüntüde çok segmentasyonu ifade ederken, negatif AFI eksik segmentasyonu ifade eder Qr metriğinde referans objesi ile ele alınan segmentler arasındaki kesişen alanlardaki eksik segmentasyonu ve çok segmentasyon sonuçlarına göre belirlemektedir. Qr değerlerin 0 ve 1 arasında olması gerekmektedir. Qr değeri ne kadar 1’e yakın olursa daha iyi sonuç elde edilmektedir [Tonbul ve Kavzoğlu,2017]. Bu çalışmada 1 ve 4. referans alanları için görüntüde çok segmentasyonu ifade ederken, 2,3 ve 5 referans alanları için eksik segmentasyonu göstermektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin AFI ve Qr değerleri 1 numaralı referans alanının sırasıyla değerleri 0.039 ve 0.960 ve 3 numaralı referans alanının sırasıyla değerleri -0.032 ve 0.968 olarak elde edilmiştir.

Tablo 4.3: Rize ili 2016 yılı ortalama segmentasyonu kalite metrikleri.


Referans alan	Ar	As	Quality Rate (Qr)	Area Fit Index (AFI)
1	8751.408	8401.906	0.960063341	0.039936659
2	13939.298	14502.731	0.961149869	-0.040420472
3	19755.445	20404.732	0.968179587	-0.03286623
4	12309.95	11402.598	0.926291171	0.073708829
5	4665.428	5101.185	0.914577299	-0.093401291

Segmentasyon işleminden sonra sınıflandırma işleminde kullanılmak üzere segmente edilen görüntüden her bir sınıf için görüntüde homojen olacak şekilde örnek toplanmıştır. Sınıflandırma sonuçlarını analiz edebilmek için bölgesel istatistikler hesaplanmıştır. Vektör katman yardımıyla raster katmanının piksellerini ortalama değer ve standart sapma parametreleri hesaplanmaktadır. Bu işlem sonucunda segmentlerin kullanılan bantlardaki (mavi, yeşil ve kırmızı) minimum, maksimum, ortalama değer ve standart sapma parametreleri elde edilmiştir.

Nitelikler konuma göre birleştirildi. Bu işlem adımı temel katman olarak bölgesel istatistik sonucu oluşan dosya seçildi. Birleştirilecek katman sınıflar için ilk adımda oluşan segmentler seçildi. Birleştirme türü olarak yalnızca ilk eşleşen özelliğin öznitelikleri seçildi ve sonucunda birleştirilen katman oluşturuldu.

Bir sonraki işlem adımı olarak eğitim vektör sınıflandırıcısı işlemi yapıldı. Bu sınıflandırmada giriş vektör verisi olarak birleştirilmiş katman seçildi. Eğitim

özellikleri seçiminde oluşan her segment için ortalama ve standart değerler (mean_0, stdev_0, mean_1, stdev_1, mean_2 ve stdev_2) kullanılan Mavi, Yeşil ve Kırmızı bant için alınan değerler Şekil 4.6’de gösterilmiştir.



DN	count	mean_0	stdev_0	min_0	max_0	mean_1	stdev_1
1	19.0000000000...	611.631578947...	16.2111433770...	591.000000000...	646.000000000...	500.684210526...	17.1983611350...
2	24.0000000000...	581.000000000...	12.6284702505...	558.000000000...	611.000000000...	467.208333333...	12.7483303822...
3	14.0000000000...	591.714285714...	6.26870826380...	579.000000000...	602.000000000...	492.000000000...	8.97860705317...
4	17.0000000000...	560.882352941...	10.0615751310...	544.000000000...	577.000000000...	461.411764705...	7.04502327470...
5	15.0000000000...	580.333333333...	12.9210054156...	558.000000000...	611.000000000...	520.533333333...	13.4316612453...
6	17.0000000000...	530.882352941...	8.29067513038...	515.000000000...	545.000000000...	433.470588235...	5.44423602375...
7	13.0000000000...	608.615384615...	9.86186646920...	592.000000000...	627.000000000...	501.076923076...	7.26247820950...
8	21.0000000000...	569.428571428...	12.5959177060...	544.000000000...	591.000000000...	453.333333333...	14.5579302558...
9	33.0000000000...	616.242424242...	14.8724373906...	587.000000000...	642.000000000...	519.848484848...	18.3543612190...
10	23.0000000000...	572.956521739...	12.8646035195...	545.000000000...	594.000000000...	472.913043478...	10.7615183259...
11	28.0000000000...	564.464285714...	6.50061047194...	550.000000000...	577.000000000...	471.107142857...	6.41952626447...
12	53.0000000000...	483.396226415...	11.6377033529...	461.000000000...	516.000000000...	369.811320754...	10.5046813809...
13	18.0000000000...	496.277777777...	11.2762402764...	483.000000000...	519.000000000...	384.500000000...	14.1681083464...
14	26.0000000000...	587.615384615...	7.45158733735...	579.000000000...	602.000000000...	496.230769230...	8.54310338135...
15	12.0000000000...	600.833333333...	10.9447649032...	581.000000000...	624.000000000...	492.833333333...	8.27738796451...
16	13.0000000000...	595.692307692...	13.5424309449...	568.000000000...	616.000000000...	495.538461538...	9.51853791832...
17	20.0000000000...	577.049999999...	9.59975328630...	559.000000000...	595.000000000...	469.100000000...	8.93779673780...
18	34.0000000000...	590.117647058...	6.87447940015...	578.000000000...	602.000000000...	501.558823529...	6.89835806757...
19	11.0000000000...	474.090909090...	9.67940644310...	463.000000000...	497.000000000...	359.727272727...	4.64953565618...
20	16.0000000000...	484.187500000...	10.2386115595...	470.000000000...	503.000000000...	373.750000000...	9.99666611092...
21	23.0000000000...	666.695652173...	29.6025717288...	614.000000000...	734.000000000...	567.217391304...	34.9544593614...
22	18.0000000000...	600.888888888...	51.3040405344...	532.000000000...	706.000000000...	493.666666666...	54.0392014570...
23	11.0000000000...	526.818181818...	23.8025972608...	492.000000000...	561.000000000...	417.000000000...	25.9268200904...
24	47.0000000000...	626.744680851...	10.1305995468...	600.000000000...	647.000000000...	524.872340425...	11.6313239391...

Şekil 4.6: Rize ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Sınıflandırma işlemine geçilmeden önce görüntüde eğitim ve test verileri seçildi. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir.

Denetim için sınıf tamsayı etiketi içeren alan olarak sınıf_id seçildi. Sınıflandırma için destek vektör makineleri seçildi. Destek vektör makinelerinde çekirdek tipi olarak doğrusal destek vektör makinesi seçildi ve bunun sonucunda nesne tabanlı model oluşturuldu. Model oluşturulduktan sonra vektör sınıflandırıcısı işlemi yapıldı. Bu işlem adımında giriş vektör veri olarak segmentasyon istatistik seçildi ve model olarak oluşturduğumuz model seçildi. Eğitim özellikleri için alan isimlerinde ortalama ve standart özellikler her bant için yazıldı. Bu işlem sonucunda nesne tabanlı sınıflandırma yapıldı.

gereken 36 pikselin yapı alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 2865 piksel sayısında 755'i boş alan, 642'si yapı alanları, 624'ü vejetasyon alanı ve 844'ü su alanları olarak sınıflandırılmıştır.

Tablo 4.4: Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)					
Sınıflar	Boş alan	Yapı alanları	Vejetasyon	Su alanları	Toplam
Boş alan	743	0	18	0	761
Yapı alanları	12	574	31	12	629
Vejetasyon	0	32	575	0	607
Su alanları	0	36	0	832	868
Toplam	755	642	624	844	2865

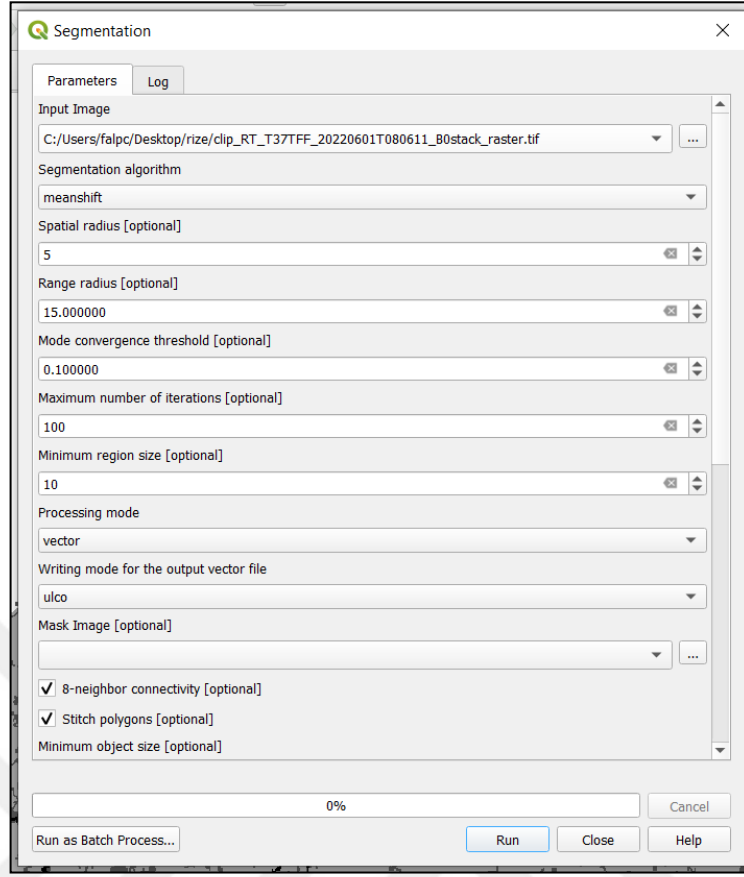
Sınıflandırma sonucu Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.5'de gösterilmiştir.

Tablo 4.5'den de görüleceği üzere Rize ili 2016 yılındaki boş alan sınıflandırmasında %68 en düşük üretici doğruluğu, %99 ile en yüksek üretici doğruluğu (ÜD) su alanları sınıflandırılmasında elde edilmiştir. Yapı alanları sınıflandırmasında %91 ile en düşük kullanıcı doğruluğu (KD) ve boş alan sınıflandırmasında %97 ile en yüksek kullanıcı doğruluğu elde edilmiştir.

Tablo 4.5: Rize ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.


Alan Bazlı Hata Matrisi					
Sınıflar	Boş alan	Yapı alanı	Vejetasyon alanı	Su alanı	Alan
Boş alan	0.0046	0	0.0001	0	276600
Yapı alanı	0.0022	0.103	0.0056	0.0022	6610000
Vejetasyon alanı	0	0.026	0.4675	0	28898000
Su alanı	0	0.0161	0	0.3728	22775400
Toplam	0.0068	0.1452	0.4731	0.3749	58560000
Alan	396162	8500074	27706860	21956903	58560000
ÜD [%]	68.17	70.96	98.8	99.42	
KD [%]	97.63	91.26	94.73	95.85	

QGIS yazılımında segmentasyon yapılırken Rize ili 2022 yılı görüntüsü için uzaysal yarıçap 5, alan yarıçapı 15, mod yakınsama eşiği 0.10, maksimum yineleme sayısı 100, minimum bölge boyutu 10 ve sekiz komşu bağlantısı seçilmiştir. Şekil 4.8’de segmentasyon parametre seçimi arayüzü gösterilmiştir.



Şekil 4.8: Rize ili 2022 yılı segmentasyon parametre seçim arayüzü.

Seçilen parametreler sonucunda segmentasyon görüntüleri oluşturulmuştur. Oluşturulan segmentasyon görüntüleri Rize ili 2022 yılı için Şekil 4.9’da gösterilmiştir.



Şekil 4.9: Rize ili 2022 yılı ortalama kayma segmentasyon haritası.

Rize ili 2022 yılı görüntüsünde oluşan segmentler sonucu segmentlere ait bilgiler Tablo 4.6’da gösterilmiştir. Görüntülerde oluşan segmentler sonucu 2022 yılında ise 23407 segment elde edilmiştir. Rize’de 2022 yılı görüntüdeki minimum segment alanı 100.017 m² ve maksimum segment alanı 13303.075 m² olarak elde edilmiştir.

Tablo 4.6: Rize ili 2022 yılı ortalama kayma segment bilgileri.

Rize	
2022	
Segment Sayısı	23407
Minimum Değer	1
Maksimum Değer	23510
Minimum alan	100.017
Maksimum Alan	13303.08
Ortalama değer	11715.02
Medyan değer	11704
Standart sapma	6773.45

Rize ili 2022 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2022 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.10’da gösterilmiştir.



Şekil 4.10: Rize ili 2022 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Rize ili 2022 yılı segmentasyon kalite metrikleri Tablo 4.7’de gösterilmiştir.

Tablodan da görüleceği üzere bu çalışmada 3,4 ve 5 referans alanları için görüntüde çok segmentasyonu ifade ederken, 1 ve 2 referans alanları için eksik segmentasyonu göstermektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri

sırasıyla -0.004 ve 0.996 olarak hesaplanırken, 3 numaralı referans alanının değerleri sırasıyla 0.002 ve 0.998 olarak hesaplanmıştır.

Tablo 4.7: Rize ili 2022 yılı ortalama kayma segmentasyon kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit İndex (AFI)
1	2869206.205	2880499.024	0.996079562	-0.003935869
2	14872.325	15503.552	0.959285008	-0.042443061
3	4909.38	4901.019	0.998296934	0.001703066
4	8034.526	7201.646	0.896337382	0.103662618
5	3122.492	3100.646	0.993003665	0.006996335

Segmentasyon işleminden sonra segmente edilen görüntüden her bir sınıf için görüntüde homojen olacak şekilde örnek toplanmıştır. Bölgesel istatistik işlemi yapıldı. Bölgesel istatistik ile sınıflandırmanın sonuçlarını analiz edebilmek için bu yöntem kullanılmaktadır. Vektör katmanının yardımıyla raster katmanının piksellerini ortalama değer ve standart sapma parametreleri hesaplanmaktadır. Bu işlem sonucunda segmentlerin kullanılan bantlardaki (Mavi, Yeşil ve Kırmızı) minimum, maksimum, ortalama değer ve standart sapma parametreleri elde edilmiştir.

Nitelikler konuma göre birleştirildi. Bu işlem adımı temel katman olarak bölgesel istatistik sonucu oluşan dosya seçildi. Birleştirilecek katman sınıflar için ilk adımda oluşan segmentler seçildi. Birleştirme türü olarak yalnızca ilk eşleşen özelliğin öznitelikleri seçildi ve sonucunda birleştirilen katman oluşturuldu.

Bir sonraki işlem adımı olarak eğitim vektör sınıflandırıcısı işlemi yapıldı. Bu sınıflandırmada giriş vektör verisi olarak birleştirilmiş katman seçildi. Eğitim özellikleri seçiminde oluşan her segment için ortalama ve standart değerler (mean_0, stdev_0, mean_1, stdev_1, mean_2 ve stdev_2) kullanılan Mavi, Yeşil ve Kırmızı bant için alınan değerler Şekil 4.11’de gösterilmiştir.


	DN	count	mean_0	stdev_0	min_0	max_0	mean_1	stdev_1
1	1	35.0000000000...	2632.57142857...	11.7179744141...	2613.00000000...	2666.00000000...	2264.48571428...	11.2730063544
2	2	16.0000000000...	2635.12500000...	6.51024833115...	2623.00000000...	2648.00000000...	2263.75000000...	10.8412791373
3	3	41.0000000000...	2643.43902439...	12.2883049695...	2609.00000000...	2667.00000000...	2270.04878048...	12.8042009112
4	4	15.0000000000...	2653.33333333...	12.7652802927...	2620.00000000...	2672.00000000...	2291.86666666...	12.1058820807
5	5	20.0000000000...	2646.50000000...	10.0184041170...	2630.00000000...	2661.00000000...	2276.30000000...	10.8777900232
6	6	26.0000000000...	2662.46153846...	12.7631681622...	2629.00000000...	2691.00000000...	2287.65384615...	13.0320905696
7	7	23.0000000000...	2659.39130434...	8.96832370288...	2642.00000000...	2673.00000000...	2293.91304347...	10.6767080535
8	8	17.0000000000...	2656.05882352...	11.5296931238...	2636.00000000...	2672.00000000...	2296.64705882...	15.3090707444
9	9	17.0000000000...	2651.17647058...	9.74188953770...	2636.00000000...	2669.00000000...	2293.11764705...	14.0707247189
10	10	15.0000000000...	2655.19999999...	7.12340207648...	2644.00000000...	2670.00000000...	2309.73333333...	8.59789564510
11	11	29.0000000000...	2663.86206896...	13.3703406782...	2637.00000000...	2689.00000000...	2312.93103448...	12.8339144303
12	12	22.0000000000...	2660.27272727...	12.5021210321...	2636.00000000...	2686.00000000...	2304.22727272...	15.5836661075
13	13	15.0000000000...	2671.59999999...	10.9074024667...	2652.00000000...	2687.00000000...	2318.80000000...	10.9100216052
14	14	14.0000000000...	2655.21428571...	12.1476719607...	2629.00000000...	2672.00000000...	2299.57142857...	8.44633999676
15	15	13.0000000000...	2663.92307692...	17.9465016946...	2639.00000000...	2702.00000000...	2318.61538461...	17.9189771914
16	16	21.0000000000...	2671.09523809...	11.2200925215...	2652.00000000...	2689.00000000...	2318.90476190...	12.8097804895
17	17	13.0000000000...	2660.15384615...	11.9222911238...	2636.00000000...	2680.00000000...	2312.46153846...	10.5563202602
18	18	25.0000000000...	2674.88000000...	10.5921354472...	2656.00000000...	2693.00000000...	2318.15999999...	13.6951329554
19	19	19.0000000000...	2674.31578947...	11.3825042723...	2646.00000000...	2691.00000000...	2323.31578947...	11.1407791049
20	20	12.0000000000...	2675.66666666...	8.66899735563...	2664.00000000...	2692.00000000...	2315.58333333...	12.7454685946
21	21	15.0000000000...	2675.19999999...	9.77021713461...	2658.00000000...	2691.00000000...	2331.06666666...	9.93167132150
22	22	15.0000000000...	2668.66666666...	13.9266787481...	2644.00000000...	2689.00000000...	2321.06666666...	14.7089218147
23	23	16.0000000000...	2666.00000000...	12.4632793972...	2645.00000000...	2692.00000000...	2319.68750000...	14.4393847976
24	24	11.0000000000...	2666.63636363...	13.4035273512...	2652.00000000...	2698.00000000...	2316.54545454...	8.48956578822

Şekil 4.11: Rize ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Sınıflandırma işlemine geçilmeden önce görüntüde eğitim ve test verileri seçildi. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir.

Denetim için sınıf tamsayı etiketi içeren alan olarak sınıf_id seçildi. Sınıflandırma için destek vektör makineleri seçildi. Destek vektör makinelerinde çekirdek tipi olarak doğrusal destek vektör makinesi seçildi ve bunun sonucunda nesne tabanlı model oluşturuldu. Model oluşturulduktan sonra vektör sınıflandırıcısı işlemi yapıldı. Bu işlem adımı giriş vektör veri olarak segmentasyon istatistik seçildi ve model olarak oluşturduğumuz model seçildi. Eğitim özellikleri için alan isimlerinde ortalama ve standart özellikler her bant için yazıldı. Bu işlem sonucunda nesne tabanlı sınıflandırma yapıldı.

Nesne tabanlı sınıflandırma sonucunda sınıflandırma haritası oluşturulmuştur. Oluşturulan sınıflandırma haritası Rize ili 2016 yılı görüntüsü için Şekil 4.12’de gösterilmiştir.



Şekil 4.12: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.

Oluşturulan sınıflandırma sonucu tematik haritanın sınıflandırma doğruluğu %93.08 ve Kappa sınıflandırılması 0.8866 elde edilmiştir. Sınıflandırma sonucunda oluşturulan Şekil 4.12'deki tematik haritada gösterilen dört sınıf için alan hesaplanması yapılmıştır. Yapı alanları 8228607.449 m², vejetasyon alanları 29685539.408 m², su alanları 20279497.449 m² ve boş alan 344550.482 m² olarak elde edilmiştir. Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi Tablo 4.8'de gösterilmiştir.

Referans veride hata matrisinde boş alan olarak sınıflandırılması gereken 22 pikselin vejetasyon olarak sınıflandırılmıştır. Yapı alanları olarak sınıflandırılması gereken 64 pikselin 12'si boş alan, 26'sı vejetasyon alanı ve 26'sı su alanı olarak sınıflandırılmıştır. Vejetasyon alanı olarak sınıflandırılması gereken 53 pikselin 30'u yapı alanları ve 23'ü su alanları olarak sınıflandırılmıştır. Su alanları olarak sınıflandırılması gereken 13 pikselin vejetasyon alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 2033 piksel sayısında 265'i boş alan, 436'sı yapı alanları, 637'si vejetasyon alanı ve 695'i su alanları olarak sınıflandırılmıştır.

Tablo 4.8: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)					
Referans					
Sınıflar	Boş alan	Yapı alanları	Vejetasyon	Su alanları	Toplam
Boş alan	253	0	22	0	275
Yapı alanları	12	406	26	26	470
Vejetasyon	0	30	576	23	629
Su alanları	0	0	13	646	659
Toplam	265	436	637	695	2033

Sınıflandırma sonucu Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.9’da gösterilmiştir.

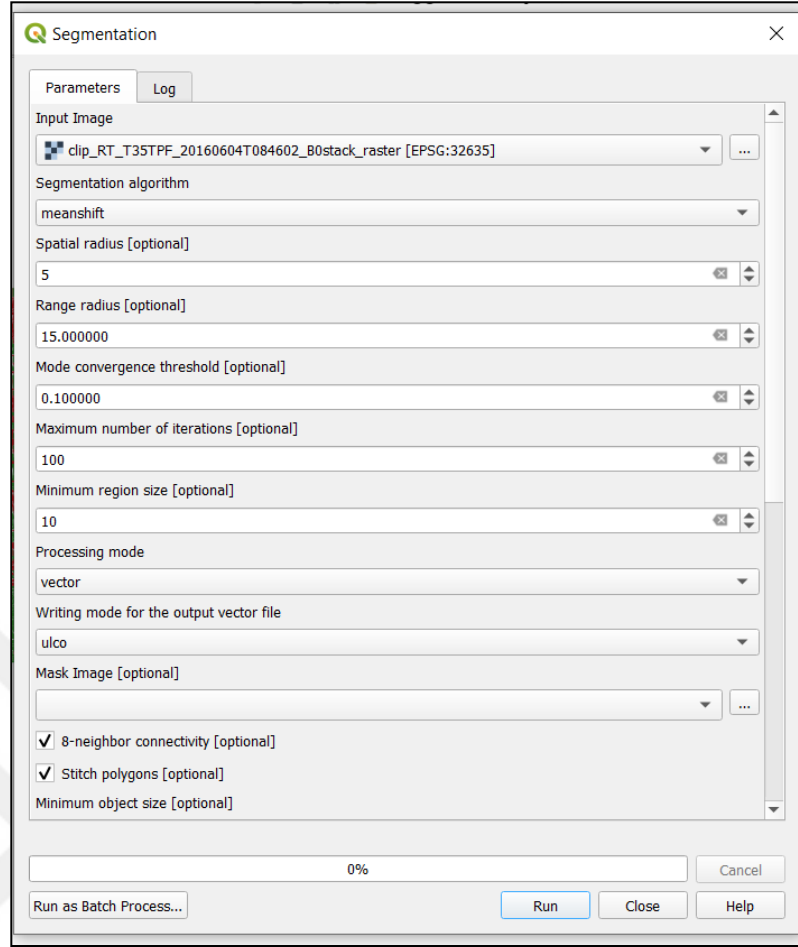
Tablo 4.9’dan da görüleceği üzere Rize ili 2022 yılındaki boş alan sınıflandırmasında %62 en düşük üretici doğruluğu, %96 ile en yüksek üretici doğruluğu vejetasyon alanları sınıflandırılmasında elde edilmiştir. Yapı alanları sınıflandırmasında %86 ile en düşük kullanıcı doğruluğu ve su alanı sınıflandırmasında %98 ile en yüksek kullanıcı doğruluğu elde edilmiştir.

Tablo 4.9: Rize ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi					
Sınıflar	Boş alan	Yapı alanı	Vejetasyon alanı	Su alanı	Alan
Boş alan	0.0059	0.0000	0.0005	0.0000	377800
Yapı alanı	0.0036	0.1214	0.0078	0.0078	8227000
Vejetasyon alanı	0.0000	0.0242	0.4641	0.0185	29679800
Su alanı	0.0000	0.0000	0.0068	0.3394	20275400
Toplam	0.0095	0.1455	0.4792	0.3657	58560000
Alan	396162	8500074	27706860	21956903	58560000
ÜD [%]	62.33	83.39	96.84	92.81	
KD [%]	92.00	86.38	91.57	98.03	


Bu çalışmada Yalova'daki 2016 ve 2021 yılı çalışma bölgelerine QGIS yazılımında segmentasyon ayrı ayrı yapılmıştır. Yalova'daki çalışma alanında sınıf değeri üç alınmıştır ve görüntüde üç sınıf oluşturulmuştur. Bu sınıflar boş alan, yapı ve vejetasyon alanlarıdır.

QGIS yazılımında segmentasyon yapılırken Yalova ili 2016 yılı görüntüsü için uzaysal yarıçap 5, alan yarıçapı 15, mod yakınsama eşiği 0.10, maksimum yineleme sayısı 100, minimum bölge boyutu 10 ve sekiz komşu bağlantısı seçilmiştir. Şekil 4.13'de segmentasyon parametre seçimi arayüzü gösterilmiştir.



Şekil 4.13: Yalova ili 2016 yılı görüntüsü için segmentasyon parametre seçim arayüzü.

Seçilen parametreler sonucunda segmentasyon görüntüleri oluşturulmuştur. Oluşturulan segmentasyon görüntüleri Yalova ili 2016 yılı için Şekil 4.14’te gösterilmiştir.



Şekil 4.14: Yalova ili 2016 yılı ortalama kayma segmentasyon haritası.


Yalova ili 2016 yılı görüntüsünde oluşan segmentler sonucu segmentlere ait bilgiler Tablo 4.10’da gösterilmiştir.

Tablo 4.10: Yalova ili 2016 yılı ortalama kayma segment bilgileri.

Yalova	
2016	
Segment Sayısı	12607
Minimum Değer	1
Maksimum Değer	12670
Minimum alan	99.98
Maksimum Alan	11997.69
Ortalama değer	6314.64
Medyan değer	6304
Standart sapma	3653.71

Yalova’da 2016 yılında 12607 segment elde edilmiştir. Yalova’da 2016 yılı görüntüdeki minimum segment alanı 99.98 m² ve maksimum segment alanı ise 11997.69 m² olarak elde edilmiştir.

Yalova ili 2016 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2016 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.15’de gösterilmiştir.



Şekil 4.15: Yalova ili 2016 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Yalova ili 2016 yılı segmentasyon kalite metrikleri Tablo 4.11’de gösterilmiştir.

Tablo 4.11’den da görüleceği üzere bu çalışmada 2 ve 5 referans alanları için görüntüde çok segmentasyonu ifade ederken, 1,3 ve 4 referans alanları için eksik segmentasyonu göstermektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri sırasıyla -0.066 ve 0.938 olarak hesaplanırken, 5 numaralı referans alanının değerleri sırasıyla 0.002 ve 0.998 olarak hesaplanmıştır.

Tablo 4.11: Yalova ili 2016 yılı ortalama kayma segmentasyonu kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit İndex (AFI)
1	21000.729	22396.833	0.937665115	-0.066478835
2	10539.562	10198.558	0.967645335	0.032354665
3	12939.683	13798.217	0.937779352	-0.066348921
4	5885.47	6999.074	0.840892667	-0.189212416
5	8015.481	7998.857	0.997926013	0.002073987

Segmentasyon işleminden sonra segmente edilen görüntüden her bir sınıf için görüntüde homojen olacak şekilde örnek toplanmıştır. Bölgesel istatistik işlemi yapıldı. Bölgesel istatistik ile sınıflandırmanın sonuçlarını analiz edebilmek için bu yöntem kullanılmaktadır. Vektör katmanının yardımıyla raster katmanının piksellerini ortalama değer ve standart sapma parametreleri hesaplanmaktadır. Bu işlem sonucunda segmentlerin kullanılan bantlardaki (Mavi, Yeşil ve Kırmızı) minimum, maksimum, ortalama değer ve standart sapma parametreleri elde edilmiştir.

Nitelikler konuma göre birleştirildi. Bu işlem adımında temel katman olarak bölgesel istatistik sonucu oluşan dosya seçildi. Birleştirilecek katman sınıflar için ilk adımda oluşan segmentler seçildi. Birleştirme türü olarak yalnızca ilk eşleşen özelliğin öznitelikleri seçildi ve sonucunda birleştirilen katman oluşturuldu.

Bir sonraki işlem adımı olarak eğitim vektör sınıflandırıcısı işlemi yapıldı. Bu sınıflandırmada giriş vektör verisi olarak birleştirilmiş katman seçildi. Eğitim özellikleri seçiminde oluşan her segment için ortalama ve standart değerler (mean_0, stdev_0, mean_1, stdev_1, mean_2 ve stdev_2) kullanılan Mavi, Yeşil ve Kırmızı bant için alınan değerler Şekil 4.16'de gösterilmiştir.

classified2016 — Features Total: 12608, Filtered: 12608, Selected: 0

	DN	count	mean_0	stdev_0	min_0	max_0	mean_1	stdev_1
1	1	13.0000000000...	805.461538461...	69.3885381800...	694.000000000...	891.000000000...	1058.92307692...	76.9019522275...
2	2	18.0000000000...	554.777777777...	48.2829351848...	480.000000000...	626.000000000...	782.944444444...	41.5217479829...
3	3	25.0000000000...	692.200000000...	72.5999311294...	627.000000000...	924.000000000...	904.440000000...	71.3109855959...
4	4	11.0000000000...	633.000000000...	38.8381255984...	566.000000000...	686.000000000...	842.272727272...	38.6395934478...
5	5	14.0000000000...	639.142857142...	121.889519422...	517.000000000...	862.000000000...	840.500000000...	145.150717425...
6	6	17.0000000000...	831.470588235...	78.0537616382...	678.000000000...	939.000000000...	1014.82352941...	85.7876996530...
7	7	23.0000000000...	673.652173913...	143.259335312...	494.000000000...	1010.0000000...	902.478260869...	153.005605828...
8	8	34.0000000000...	774.529411764...	45.4907485060...	639.000000000...	900.000000000...	1002.70588235...	53.6794805397...
9	9	19.0000000000...	477.421052631...	11.3348812152...	452.000000000...	496.000000000...	734.263157894...	12.8488741627...
10	10	12.0000000000...	741.916666666...	108.175327663...	641.000000000...	967.000000000...	989.250000000...	128.797321400...
11	11	14.0000000000...	658.785714285...	90.9363078638...	515.000000000...	812.000000000...	845.785714285...	116.278299166...
12	12	15.0000000000...	857.733333333...	134.251079626...	626.000000000...	1069.0000000...	1079.06666666...	131.091280448...
13	13	16.0000000000...	841.187500000...	229.720763464...	525.000000000...	1123.0000000...	1073.43750000...	243.652202603...
14	14	12.0000000000...	640.416666666...	137.384965654...	486.000000000...	878.000000000...	870.750000000...	158.210518556...
15	15	23.0000000000...	695.217391304...	143.835435171...	467.000000000...	940.000000000...	913.391304347...	155.177241516...
16	16	13.0000000000...	1006.15384615...	162.334965505...	711.000000000...	1251.0000000...	1280.53846153...	167.621903592...
17	17	12.0000000000...	499.500000000...	25.0617419404...	477.000000000...	560.000000000...	725.500000000...	39.8440140365...
18	18	20.0000000000...	1236.90000000...	202.950318006...	864.000000000...	1579.0000000...	1526.1500000...	192.200080782...
19	19	17.0000000000...	540.352941176...	67.8472007311...	393.000000000...	673.000000000...	759.058823529...	72.7662959310...
20	20	25.0000000000...	674.320000000...	172.475292916...	377.000000000...	954.000000000...	900.639999999...	200.765177923...
21	21	14.0000000000...	636.357142857...	89.7300285410...	545.000000000...	895.000000000...	841.000000000...	70.9821212592...
22	22	17.0000000000...	675.411764705...	130.992871382...	486.000000000...	908.000000000...	843.235294117...	134.850625421...
23	23	24.0000000000...	819.791666666...	276.494512747...	606.000000000...	1724.0000000...	1056.5000000...	294.682290227...
24	24	12.0000000000...	514.333333333...	43.8765485783...	461.000000000...	586.000000000...	742.000000000...	42.3212819878...

Show All Features

Şekil 4.16: Yalova ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Sınıflandırma işlemine geçilmeden önce görüntüde eğitim ve test verileri seçildi. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir.

Denetim için sınıf tamsayı etiketi içeren alan olarak sınıf_id seçildi. Sınıflandırma için destek vektör makineleri seçildi. Destek vektör makinelerinde çekirdek tipi olarak doğrusal destek vektör makinesi seçildi ve bunun sonucunda nesne tabanlı model oluşturuldu. Model oluşturulduktan sonra vektör sınıflandırıcısı işlemi yapıldı. Bu işlem adımında giriş vektör veri olarak segmentasyon istatistik seçildi ve model olarak oluşturduğumuz model seçildi. Eğitim özellikleri için alan isimlerinde ortalama ve standart özellikler her bant için yazıldı. Bu işlem sonucunda nesne tabanlı sınıflandırma yapıldı.

2348 piksel sayısında 1114'ü yapı alanı, 629'u vejetasyon alanları ve 605'i boş alanı olarak sınıflandırılmıştır.

Tablo 4.12: Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Toplam
Yapı alanları	1017	140	132	1289
Vejetasyon	86	461	0	547
Boş alan	11	28	473	512
Toplam	1114	629	605	2348


Sınıflandırma sonucu Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.13'de gösterilmiştir.

Tablo 4.13'den de görüleceği üzere Yalova ili 2016 yılındaki boş alan sınıflandırmasında %62 en düşük üretici doğruluğu, %94 ile en yüksek üretici doğruluğu vejetasyon alanları sınıflandırılmasında elde edilmiştir. Yapı alanları sınıflandırmasında %78 ile en düşük kullanıcı doğruluğu ve boş alan sınıflandırmasında %92 ile en yüksek kullanıcı doğruluğu elde edilmiştir.

Tablo 4.13: Yalova ili 2016 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.


Alan Bazlı Hata Matrisi				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Alan
Yapı alanları	0.1720	0.0237	0.0223	6479400
Vejetasyon	0.0998	0.5351	0.0000	18869900
Boş alan	0.0032	0.0080	0.1359	4370900
Toplam	0.2750	0.5668	0.1582	29720200
Alan	8172796	16845921	4701483	29720200
ÜD [%]	62.55	94.40	85.89	
KD [%]	78.90	84.28	92.38	

QGIS yazılımında segmentasyon yapılırken Yalova ili 2022 yılı görüntüsü için uzaysal yarıçap 5, alan yarıçapı 15, mod yakınsama eşiği 0.10, maksimum yineleme sayısı 100, minimum bölge boyutu 10 ve sekiz komşu bağlantısı seçilmiştir. Şekil 4.18’de segmentasyon parametre seçimi arayüzü gösterilmiştir.



Şekil 4.18: Yalova ili 2022 yılı görüntüsü için segmentasyon parametre seçim arayüzü.

Seilen parametreler sonucunda segmentasyon grntleri oluřturulmuřtur. Oluřturulan segmentasyon grntleri Yalova ili 2022 yılı iin řekil 4.19’da gsterilmiřtir.



řekil 4.19: Yalova ili 2022 yılı ortalama kayma segmentasyon haritası.

Yalova ili 2022 yılı grntsnde oluřan segmentler sonucu segmentlere ait bilgiler Tablo 4.14’de gsterilmiřtir. Yalova’da 2022 yılında ise 12691 segment elde edilmiřtir. 2022 yılı grntde ise minimum segment alanı 99.98 m² ve maksimum segment alanı ise 11897.877 m² olarak elde edilmiřtir. Tablo 4.14’de gsterildiėi zere minimum deėer 1, maksimum deėer 12753, ortalama deėer 6356.6, medyan deėeri 6346 ve standart sapma 3677.87 olarak elde edilmiřtir.

Tablo 4.14: Yalova ili 2022 yılı segment bilgileri.

Yalova	
2022	
Segment Sayısı	12691
Minimum Değer	1
Maksimum Değer	12753
Minimum alan	99.98
Maksimum Alan	11897.88
Ortalama değer	6356.6
Medyan değer	6346
Standart sapma	3677.87

Yalova ili 2022 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2022 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.20’de gösterilmiştir.



Şekil 4.20: Yalova ili 2016 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Yalova ili 2022 yılı segmentasyon kalite metrikleri Tablo 4.15’de gösterilmiştir.

Tablo 4.15’den da görüleceği üzere bu çalışmada 2 ve 4 referans alanları için görüntüde çok segmentasyonu ifade ederken, 1,3 ve 5 referans alanları için eksik segmentasyonu göstermektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri sırasıyla -0.019 ve 0.982 olarak hesaplanırken, 4 numaralı referans alanının değerleri sırasıyla 0.002 ve 0.998 olarak hesaplanmıştır.

Tablo 4.15: Yalova ili 2022 yılı segmentasyon kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit İndex (AFI)
1	54080.999	55089.266	0.981697578	-0.018643646
2	45664.701	45391.97	0.994027531	0.005972469
3	32487.639	33487.79	0.970133861	-0.030785586
4	54297.894	54190.31	0.998018634	0.001981366
5	35588.415	35893.42	0.991502482	-0.008570345

Segmentasyon işleminden sonra segmente edilen görüntüden her bir sınıf için görüntüde homojen olacak şekilde örnek toplanmıştır. Bölgesel istatistik işlemi yapıldı. Bölgesel istatistik ile sınıflandırmanın sonuçlarını analiz edebilmek için bu yöntem kullanılmaktadır. Vektör katmanının yardımıyla raster katmanının piksellerini ortalama değer ve standart sapma parametreleri hesaplanmaktadır. Bu işlem sonucunda segmentlerin kullanılan bantlardaki (Mavi, Yeşil ve Kırmızı) minimum, maksimum, ortalama değer ve standart sapma parametreleri elde edilmiştir.

Nitelikler konuma göre birleştirildi. Bu işlem adımında temel katman olarak bölgesel istatistik sonucu oluşan dosya seçildi. Birleştirilecek katman sınıflar için ilk adımda oluşan segmentler seçildi. Birleştirme türü olarak yalnızca ilk eşleşen özelliğin öznitelikleri seçildi ve sonucunda birleştirilen katman oluşturuldu.

Bir sonraki işlem adımı olarak eğitim vektör sınıflandırıcısı işlemi yapıldı. Bu sınıflandırmada giriş vektör verisi olarak birleştirilmiş katman seçildi. Eğitim özellikleri seçiminde oluşan her segment için ortalama ve standart değerler (mean_0,

stdev_0, mean_1, stdev_1, mean_2 ve stdev_2) kullanılan Mavi, Yeşil ve Kırmızı bant için alınan değerler Şekil 4.21’de gösterilmiştir.


DN	count	mean_0	stdev_0	min_0	max_0	mean_1	stdev_1
1	32.0000000000...	451.937500000...	31.8959371464...	397.000000000...	561.000000000...	630.843750000...	37.0118632899
2	29.0000000000...	592.000000000...	20.2272800233...	550.000000000...	659.000000000...	807.275862068...	23.3894001506
3	14.0000000000...	664.500000000...	20.1942489909...	637.000000000...	704.000000000...	932.571428571...	28.3812350945
4	24.0000000000...	664.916666666...	148.850937011...	400.000000000...	954.000000000...	862.875000000...	170.671897918
5	21.0000000000...	706.142857142...	147.626991337...	422.000000000...	1055.00000000...	972.428571428...	156.395515098
6	14.0000000000...	849.642857142...	181.235336655...	663.000000000...	1345.00000000...	1175.07142857...	223.827015722
7	25.0000000000...	717.519999999...	40.2162073464...	645.000000000...	780.000000000...	1010.32000000...	36.0239734991
8	17.0000000000...	564.176470588...	117.226402366...	389.000000000...	740.000000000...	708.588235294...	106.535826616
9	11.0000000000...	932.545454545...	100.900310838...	739.000000000...	1083.00000000...	1095.72727272...	118.599402114
10	11.0000000000...	684.090909090...	63.9663263685...	620.000000000...	785.000000000...	849.181818181...	61.7912909426
11	26.0000000000...	849.192307692...	202.759763115...	475.000000000...	1198.00000000...	1056.11538461...	212.103244090
12	15.0000000000...	779.133333333...	85.6011237131...	620.000000000...	911.000000000...	877.133333333...	139.365330115
13	13.0000000000...	766.923076923...	144.916908110...	468.000000000...	979.000000000...	954.384615384...	131.867697877
14	15.0000000000...	545.733333333...	69.4503591131...	453.000000000...	649.000000000...	725.799999999...	56.9651522549
15	25.0000000000...	500.879999999...	94.053182118...	394.000000000...	660.000000000...	711.879999999...	95.1066594233
16	13.0000000000...	1450.84615384...	183.595500196...	1092.00000000...	1877.00000000...	1744.84615384...	173.615401656
17	16.0000000000...	796.687500000...	198.968244953...	485.000000000...	1122.00000000...	992.875000000...	221.334400097
18	12.0000000000...	951.166666666...	191.864930394...	641.000000000...	1298.00000000...	1196.91666666...	219.745496730
19	24.0000000000...	734.333333333...	209.535234489...	329.000000000...	1105.00000000...	910.166666666...	219.439932687
20	15.0000000000...	820.933333333...	165.025741137...	522.000000000...	1149.00000000...	946.933333333...	170.824248306
21	13.0000000000...	561.384615384...	104.764448853...	418.000000000...	737.000000000...	705.153846153...	131.476769908
22	24.0000000000...	486.000000000...	100.579624524...	340.000000000...	663.000000000...	645.000000000...	85.9676379959
23	15.0000000000...	522.600000000...	122.115168123...	399.000000000...	839.000000000...	721.333333333...	115.477682857
24	18.0000000000...	1557.77777777...	497.700306179...	962.000000000...	2580.00000000...	1930.72222222...	517.362292624

Şekil 4.21: Yalova ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Sınıflandırma işlemine geçilmeden önce görüntüde eğitim ve test verileri seçildi. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir.

Denetim için sınıf tamsayı etiketi içeren alan olarak sınıf_id seçildi. Sınıflandırma için destek vektör makineleri seçildi. Destek vektör makinelerinde çekirdek tipi olarak doğrusal destek vektör makinesi seçildi ve bunun sonucunda nesne tabanlı model oluşturuldu. Model oluşturulduktan sonra vektör sınıflandırıcısı işlemi yapıldı. Bu işlem adımında giriş vektör veri olarak segmentasyon istatistik seçildi ve model olarak oluşturduğumuz model seçildi. Eğitim özellikleri için alan isimlerinde ortalama ve standart özellikler her bant için yazıldı. Bu işlem sonucunda nesne tabanlı sınıflandırma yapıldı.

Nesne tabanlı sınıflandırma sonucunda sınıflandırma haritası oluşturulmuştur. Oluşturulan sınıflandırma haritası Yalova ili 2022 yılı görüntüsü için Şekil 4.22’de gösterilmiştir.



Şekil 4.22: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritası.

Oluşturulan sınıflandırma sonucu tematik haritanın genel doğruluğu %94.52 ve Kappa sınıflandırması 0.9005 olarak elde edilmiştir. Sınıflandırma sonucunda oluşturulan Şekil 4.22’deki tematik haritada gösterilen üç sınıf için alan hesaplanması yapılmıştır. Yapı alanları 6677951.034 m², vejetasyon alanları 18119310.426 m² ve boş alan 4918097.526 m² olarak elde edilmiştir. Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi Tablo 4.16’da gösterilmiştir.

Tablo 4.16: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Toplam
Yapı alanları	816	42	56	914
Vejetasyon	0	608	14	622
Boş alan	68	12	698	778
Toplam	884	662	768	2314

Referans veride hata matrisinde yapı alanı olarak sınıflandırılması gereken 98 pikselin 42'si vejetasyon alanı ve 56'sı boş alan olarak sınıflandırılmıştır. Vejetasyon alanları olarak sınıflandırılması gereken 14 pikselin boş alan olarak sınıflandırılmıştır. Boş alan olarak sınıflandırılması gereken 80 pikselin 68'i yapı alanları ve 12'si vejetasyon alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 2314 piksel sayısında 884'ü yapı alanı, 662'si vejetasyon alanları ve 768'i boş alan olarak sınıflandırılmıştır.

Sınıflandırma sonucu Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.17'de gösterilmiştir.


Tablo 4.17'dan de görüleceği üzere Yalova ili 2022 yılındaki boş alan sınıflandırmasında %84 ile en düşük üretici doğruluğu, %97 ile en yüksek üretici doğruluğu vejetasyon alanları sınıflandırılmasında elde edilmiştir. Yapı alanları sınıflandırmasında %89 ile en düşük kullanıcı doğruluğu ve vejetasyon alan sınıflandırmasında %97 ile en yüksek kullanıcı doğruluğu elde edilmiştir.

Tablo 4.17: Yalova ili 2022 yılı ortalama kayma segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Alan
Yapı alanları	0.2006	0.0103	0.0138	6679000
Vejetasyon	0.0000	0.5960	0.0137	18122300
Boş alan	0.0145	0.0026	0.1485	4918900
Toplam	0.2151	0.6089	0.1760	29720200
Alan	6392800	18097185	5230215	29720200
ÜD [%]	93.27	97.88	84.38	
KD [%]	89.28	97.75	89.72	


4.2.2. Çoklu Çözünürlüklü (Multi-Resolution) Segmentasyonu

Bu işlem, her pikseli bir nesne olarak işleme aldığı ve daha sonra her bir pikseli şekil, yoğunluk ve ölçek parametrelerini esas alarak komşu pikselleri birleştirerek görüntü nesneleri oluşturmasıdır. Bu çalışmada eCognition yazılımı kullanılarak çoklu çözünürlüklü segmentasyon işlemi gerçekleştirilmiştir. eCognition yazılımında elde edilen görüntüler üzerinde çoklu çözünürlüklü segmentasyon işlemi yapıp daha sonra parametreler seçilip ve segmentler birleştirildikten sonra segmente edilmiş nesneler elde edilmiştir. eCognition yazılımında kullanılan yöntemin iş akış şeması Şekil 4.23’de gösterilmiştir.




Şekil 4.23: eCognition yazılımındaki iş akış şeması.

Bu çalışmada, bölütleme için mevcut Mavi (B), Yeşil (G), Kırmızı (R) ve Yakın Kızılötesi (NIR) görüntü bantları kullanılmıştır. Bölütleme işlemine başlamak için gerekli görüntü bölütleme parametrelerinin tanımlanması gerekmektedir. Ölçek parametresi belirlemede ESP-2 parametresi kullanılmıştır. ESP-2 parametresinde görüntüde Level_1, Level_2 ve Level_3 seviyesinde ölçek değerleri üretilir. ESP-2 parametresi ile lokal varyans ve değişim oranı grafiği üretilmektedir. Rize ili 2016 yılı için görüntüde ESP-2 kullanılarak elde edilen ölçek parametreleri sonucunda LV (Local variance) grafiği Şekil 4.24’de gösterilmiştir.




Şekil 4.24: Rize ili 2016 yılı ESP-2 parametresi LV grafiği.

Rize ili 2016 yılı görüntüsünde eCognition yazılımında ESP-2 parametresi ile ölçek değerleri L1 78, L2 258 ve L3 258 ölçek değerleri elde edilmiştir. L1 değeri 78 olan ölçek parametresi için segmentasyon sonucu Şekil 4.25’de elde edilmiştir.



Şekil 4.25: L1 değeri 78 olan ölçek parametresi için segmentasyon sonucu.


L2 ve L3 değeri 258 olan ölçek parametresi için segmentasyon sonucu Şekil 4.26’da elde edilmiştir.



Şekil 4.26: L2 ve L3 değeri 258 olan ölçek parametresi için segmentasyon sonucu.


Şekil 4.25 ve Şekil 4.26'dan de görüleceği üzere L1 seviyesinden L3 seviyesine doğru görüntüdeki görüntü nesne sayısı azalmaktadır. L2 ve L3 seviyesinde görüntüde 115 segment üretilmiştir. L1 seviyesinde 1041 segment üretilmiştir. L1 seviyesi sonucu oluşan görüntüde ölçek parametresi Rize ili 2016 yılı için en iyi ölçeği göstermektedir.

Görüntü bölütleme işleminde Ölçek 78, Şekil 0.1, Kompaktlık 0.5 ve Görüntü Katmanı Ağırlıkları 1,1,1,1 olarak parametreler kullanıldığı Şekil 4.27'de gösterilmiştir.



Şekil 4.27: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon parametreleri.


Bu parametrelerden ölçek, görüntü nesnelerinin izin verilen en yüksek heterojenlik seviyesini belirler ve ortalama nesne boyutunu etkiler. Ölçek parametre değeri ne kadar yüksek olursa, görüntü nesneleri o kadar büyük olur, parametre değeri azaldıkça küçük ve fazla görüntü nesneleri üretilir. Şekil/Renk parametresi, şekil ve renk homojenliğinin görüntü nesnelerinin oluşturulması üzerindeki etkisini ayarlar. Şekil değeri ne kadar yüksek olursa, nesne oluşumunu o kadar az spektral homojenlik etkiler. Yumuşaklık/kompaktlık parametresi, elde edilen nesnenin yoğunluğunu veya düzgünlüğünü belirler. Seçilen bir şekil değeri ile kullanıcı, nihai nesnenin yoğunluğunu veya düzgünlüğünü etkileyebilir. Görüntü Katmanı Ağırlıkları parametresi, görüntü bölütleme de kullanılan her bir spektral bandın ağırlığını belirler. Seçilen parametreler sonucunda Rize ili 2016 yılı için segmentasyon görüntüsü oluşturulmuştur. Oluşturulan segmentasyon görüntüsü Rize ili 2016 yılı için Şekil 4.28’de gösterilmiştir.



Şekil 4.28: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon haritası.

Yapılan segmentasyon sonucu Rize ili 2016 yılı 1041 segment elde edilmiştir. Şekil 4.28’de gösterilen segmentasyon haritasında minimum segment alanı 300.058 m² ve maksimum segment alanı 1585133.864 m² olarak elde edilmiştir.

Segmentasyon kalitesinin değerlendirilmesi için Rize ili 2016 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2016 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.29’da gösterilmiştir.



Şekil 4.29: Rize ili 2016 yılı segmentlerin referans nesnelerle olan örtüşme alanları.


Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri Tablo 4.18’de gösterilmiştir.

Tablo 4.18’den de görüleceği üzere bu çalışmada bütün referans alanları için görüntüde çok segmentasyonu ifade etmektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri sırasıyla 0.005 ve 0.995 olarak hesaplanırken, 3 numaralı referans alanının değerleri sırasıyla 0.030 ve 0.969 olarak hesaplanmıştır.

Tablo 4.18: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit İndex (AFI)
1	10153.371	10102.29	0.99496906	0.00503094
2	6831.742	6601.185	0.966252092	0.033747908
3	3404.41	3300.753	0.96955214	0.03044786
4	6256.354	5601.008	0.895251132	0.104748868
5	11542	10902.486	0.944592445	0.055407555

Sınıflandırma öncesinde segmentlere ait öznitelikler seçildi. Kullanılan Kırmızı, Yeşil ve Mavi bantları için parlaklık, ortalama katman ve maksimum fark öznitelikleri kullanıldı. Oluşturulan her segment için bu öznitelikler kullanıldı. Rize ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri Şekil 4.30’da gösterilmiştir.




	Max_diff	Mean_Layer	Mean_Layer_1	Mean_Layer_2	Class_name	Brightness
1	885918961	1312.09090909...	942.977272727...	748.068181818...	1	883.625000000...
2	1.10290996825...	1298.38509316...	796.993788819...	642.503105590...	1	790.973602484...
3	0.98943728279...	1174.59322033...	713.423728813...	642.237288135...	1	742.538135593...
4	0.94020101136...	1380.23529411...	1088.41176470...	759.976470588...	1	932.929411764...
5	0.91558542258...	1592.68888888...	1266.46666666...	831.044444444...	1	1074.72222222...
6	0.91860386002...	1362.25000000...	1007.00000000...	786.750000000...	1	918.604166666...
7	1.03339973671...	1359.18000000...	874.139999999...	728.120000000...	1	858.389999999...
8	0.87311110629...	1541.46875000...	1299.00000000...	891.187500000...	1	1082.08593750...
9	0.95483009812...	1384.41025641...	922.743589743...	781.948717948...	1	902.858974358...
10	0.93808570284...	1024.93103448...	601.965517241...	537.068965517...	1	645.775862068...
11	1.02462938154...	1122.04166666...	727.833333333...	583.375000000...	1	707.572916666...
12	0.97966972477...	1024.55072463...	623.782608695...	522.855072463...	1	641.757246376...
13	1.01460394878...	1276.63636363...	835.075757575...	661.893939393...	1	807.689393939...
14	1.06380616392...	1178.84210526...	751.473684210...	611.473684210...	1	734.750000000...
15	1.05791278662...	1022.04615384...	527.392307692...	537.030769230...	1	614.584615384...
16	1.04552989871...	1138.27272727...	697.303030303...	600.030303030...	1	708.325757575...
17	1.00026074224...	1630.95588235...	1382.42647058...	854.955882352...	1	1099.80147058...
18	1.11529464186...	1282.18571428...	742.100000000...	629.528571428...	1	769.457142857...
19	0.9546108746986	1775.45454545...	1527.06060606...	946.424242424...	1	1215.91666666...

Şekil 4.30: Rize ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Segmentasyon yapıldıktan sonra sınıflandırma işlemine geçildi. Rize ili 2016 yılı için dört sınıf oluşturuldu. Bu sınıflar boş alan, yapı alanları, vejetasyon alanları ve su alanları olarak oluşturuldu. Daha sonra segmentler üzerinden sınıflar için örnek seçimi yapıldı. Örnek seçimi yapılırken görüntüde homojen olacak şekilde ve sınıflarda da

aynı sayıda olacak şekilde veri seçilmiştir. Örnek seçimleri yapıldıktan sonra standart en yakın komşu özelliğinden temel sınıflandırma işlemi yapıp ve bunun sonucunda sınıflandırma haritası elde edilmiştir. Oluşturulan sınıflandırma haritası Rize ili 2016 yılı için Şekil 4.31’de gösterilmiştir.



Şekil 4.31: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.

Oluşturulan sınıflandırma sonucu tematik haritanın genel doğruluğu %97.68 ve Kappa sınıflandırması 0.9602 olarak elde edilmiştir. Sınıflandırma sonucunda oluşturulan Şekil 4.31’deki tematik haritada gösterilen dört sınıf için alan hesaplanması yapılmıştır. Yapı alanları 5530125.256 m², vejetasyon alanları 29877413.333 m², boş alan 227049.117 m² ve su alanları 22936702.981 m² olarak elde edilmiştir. Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi Tablo 4.19’da gösterilmiştir.

Referans veride hata matrisinde yapı alanı olarak sınıflandırılması gereken 4 piksel boş alan olarak sınıflandırılmıştır. Vejetasyon alanları olarak sınıflandırılması gereken 154 piksel su alanları olarak sınıflandırılmıştır. Boş alan olarak sınıflandırılması gereken 12 piksel yapı alanı olarak sınıflandırılmıştır. Su alanları

olarak sınıflandırılması gereken 82 piksel yapı alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 12312 piksel sayısında 520'si boş alan, 2000 pikseli yapı alanı, 6567 pikseli vejetasyon alanı ve 3225 pikseli su alanı sınıflandırılmıştır.

Tablo 4.19: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)					
Sınıflar	Boş alan	Yapı alanları	Vejetasyon	Su alanları	Toplam
Boş alan	516	12	0	0	528
Yapı alanları	4	1906	0	0	1929
Vejetasyon	0	0	6567	154	6721
Su alanları	0	82	0	3052	3134
Toplam	520	2000	6567	3225	12312


Sınıflandırma sonucu Rize ili 2016 yılı çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.20'de gösterilmiştir.

Tablo 4.20'dan de görüleceği üzere Rize ili 2016 yılındaki en yüksek üretici doğruluğu %100 ile vejetasyon alanları ve en düşük üretici doğruluğu %90 ile yapı alanı sınıflandırmasında elde edilmiştir. Yapı alanları sınıflandırmasında %98 ile en yüksek kullanıcı doğruluğu, %97.38 ile en düşük kullanıcı doğruluğu su alanları sınıflandırılmasında elde edilmiştir. Alan bazlı hata matrisinde toplam 58560000 m²'lik alanda 233306 m²'si boş alan, 6068350 m²'si yapı alanı, 29187144 m²'si vejetasyon alanı ve 23071200 m²'si su alanı olarak elde edilmiştir.

Tablo 4.20: Rize ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi					
Sınıflar	Boş alan	Yapı alanı	Vejetasyon alanı	Su alanı	Alan
Boş alan	0.0038	0.0001	0	0	227000
Yapı alanı	0.0002	0.0933	0	0.0009	5529100
Vejetasyon alanı	0	0	0.4984	0.0117	29871600
Su alanı	0	0.0102	0	0.3814	22932300
Toplam	0.004	0.1036	0.4984	0.394	58560000
Alan	233306	6068350	29187144	23071200	58560000
ÜD [%]	95.08	90.03	100	96.8	
KD [%]	97.73	98.81	97.71	97.38	

İkinci görüntü olarak Rize ili 2022 yılı görüntüsü eCognition yazılımında ESP-2 parametresi çalıştırıldı. Rize ili 2022 yılı için görüntüde ESP-2 kullanılarak elde edilen ölçek parametreleri sonucunda LV (Local variance) grafiği Şekil 4.32’de gösterilmiştir.



Şekil 4.32: Rize ili 2022 yılı ESP-2 parametresi LV grafiği.

Rize ili 2022 yılı görüntüsünde eCognition yazılımında ESP-2 parametresi ile ölçek değerleri L1 76, L2 176 ve L3 276 ölçek değerleri elde edilmiştir. L1 değeri 76 olan ölçek parametresi için segmentasyon sonucu Şekil 4.33’de elde edilmiştir.



Şekil 4.33: Rize ili 2022 yılı için L1 değeri 76 olan ölçek parametresi için segmentasyon sonucu.

L2 değeri 176 olan ölçek parametresi için segmentasyon sonucu Şekil 4.34’de elde edilmiştir.



Şekil 4.34: Rize ili 2022 yılı için L2 değeri 176 olan ölçek parametresi için segmentasyon sonucu.


L3 değeri 276 olan ölçek parametresi için segmentasyon sonucu Şekil 4.35’de elde edilmiştir.



Şekil 4.35: Rize ili 2022 yılı için L2 değeri 276 olan ölçek parametresi için segmentasyon sonucu.


Şekil 4.33, Şekil 4.34 ve Şekil 4.35’den de görüleceği üzere L1 seviyesinden L3 seviyesine doğru görüntüdeki görüntü nesne sayısı azalmaktadır. L3 seviyesinde 84 segment elde edilmiş ve L2 seviyesindeki görüntüde 211 segment üretilmiştir. L1 seviyesinde 1027 segment üretilmiştir. L1 seviyesi sonucu oluşan görüntüde ölçek parametresi Rize ili 2022 yılı için en iyi ölçeği göstermektedir.

Görüntü bölütleme işleminde Ölçek 76, Şekil 0.1, Kompaktlık 0.5 ve Görüntü Katmanı Ağırlıkları 1,1,1,1 olarak parametreler kullanıldığı Şekil 4.36’da gösterilmiştir.



Şekil 4.36: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon parametreleri.

Seçilen parametreler sonucunda Rize ili 2022 yılı için segmentasyon görüntüsü oluşturulmuştur. Oluşturulan segmentasyon görüntüsü Rize ili 2022 yılı için Şekil 4.37’de gösterilmiştir.



Şekil 4.37: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon haritası.

Yapılan segmentasyon sonucu Rize ili 2022 yılı 1027 segment elde edilmiştir. Şekil 4.37’de gösterilen segmentasyon haritasında minimum segment alanı 300.058 m² ve maksimum segment alanı 1585133.864 m² olarak elde edilmiştir.

Segmentasyon kalitesinin değerlendirilmesi için Rize ili 2022 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2022 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.38’de gösterilmiştir.



Şekil 4.38: Rize ili 2022 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Rize ili 2022 yılı segmentasyon kalite metrikleri Tablo 4.21’de gösterilmiştir.

Tablo 4.21’den de görüleceği üzere bu çalışmada 1,3 ve 4 alanları için görüntüde çok segmentasyonu, 2 ve 5 alanları için yetersiz segmentasyonu ifade etmektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri sırasıyla 0.003 ve 0.997 olarak hesaplanırken, 5 numaralı referans alanının değerleri sırasıyla -0.023 ve 0.978 olarak hesaplanmıştır.

Tablo 4.21: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyon kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit Index (AFI)
1	18162.528	18104.133	0.996784864	0.003215136
2	19627.756	20904.505	0.938924696	-0.065048139
3	44488.047	44009.261	0.989237873	0.010762127
4	19783.357	19703.938	0.995985565	0.004014435
5	5764.886	5901.349	0.976875965	-0.023671413

Sınıflandırma öncesinde segmentlere ait öznitelikler seçildi. Kullanılan Kırmızı, Yeşil ve Mavi bantları için parlaklık, ortalama katman ve maksimum fark öznitelikleri kullanıldı. Oluşturulan her segment için bu öznitelikler kullanıldı. Rize ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri Şekil 4.39’da gösterilmiştir.

	Max_diff	Mean_Layer	Mean_Layer_1	Mean_Layer_2	Class_name	Brightness
1	0.41526536650...	1754.80024748...	1832.30687643...	2266.38518649...	4	2122.41444228...
2	0.42390511484...	1774.64122562...	1854.12813370...	2349.87242339...	4	2168.08649025...
3	0.41473554395...	1775.91456338...	1853.14244270...	2322.02364374...	4	2155.20927618...
4	0.41981835107...	1777.64548981...	1856.83365664...	2349.02812803...	4	2167.80977206...
5	0.42164312719...	1784.93092566...	1865.43688639...	2377.35624123...	4	2183.30794179...
6	0.42597524417...	1803.13535645...	1888.63053949...	2444.84682080...	4	2221.51457129...
7	0.40534648571...	1803.76047769...	1888.24087426...	2408.78729157...	4	2198.97386210...
8	0.39803466670...	1815.08233347...	1902.01448076...	2426.97724451...	4	2209.67045924...
9	0.40162794325...	1822.78614277...	1913.95740851...	2463.66976604...	4	2229.67479004...
10	0.42747752882...	1753.37364688...	1827.07204180...	2296.66293393...	4	2135.88083240...
11	0.41820396769...	1765.10085959...	1844.28022922...	2299.26332378...	4	2142.42944126...
12	0.43473750800...	1756.47632468...	1829.82995114...	2323.64280345...	4	2150.31163096...
13	0.42020701074...	1768.14045959...	1844.56196746...	2311.14394526...	4	2148.72392202...
14	0.43422913277...	1760.56072727...	1833.12799999...	2321.03927272...	4	2152.49072727...
15	0.43911314165...	1764.38664762...	1840.15458764...	2348.31167440...	4	2167.22402713...
16	0.44107964421...	1772.72561629...	1854.53429796...	2392.00214362...	4	2189.42457127...
17	0.44671444068...	1770.95964125...	1854.50672645...	2409.81742472...	4	2196.90855221...
18	0.44012785205...	1779.79199019...	1865.54658765...	2434.99203105...	4	2207.97890273...
19	0.43282353752...	1787.87620357...	1878.43741403...	2478.65887207...	4	2223.84532324...

Şekil 4.39: Rize ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Tablo 4.22: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)					
Sınıflar	Boş alan	Yapı alanları	Vejetasyon	Su alanları	Toplam
Boş alan	2071	14	13	0	2098
Yapı alanları	20	4563	46	58	4687
Vejetasyon	0	72	4834	0	4906
Su alanları	0	179	0	5962	6141
Toplam	2091	4828	4893	6020	17832

Referans veride hata matrisinde yapı alanı olarak sınıflandırılması gereken 124 pikselin 46'sı vejetasyon alanı, 20'si boş alan ve 58'i su alanı olarak sınıflandırılmıştır. Boş alan olarak sınıflandırılması gereken 27 pikselin 14'ü yapı alanları ve 13'ü vejetasyon alanları olarak sınıflandırılmıştır. Vejetasyon alanları olarak sınıflandırılması gereken 72 piksel yapı alanları olarak sınıflandırılmıştır. Su alanları olarak sınıflandırılması gereken 179 piksel yapı alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 17832 piksel sayısında 4828'i yapı alanı, 4893'ü vejetasyon alanları, 2091'i boş alan ve 6020'si su alanı olarak sınıflandırılmıştır.


Sınıflandırma sonucu Rize ili 2022 yılı ortalama kayma segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.23'de gösterilmiştir.

Tablo 4.23'den de görüleceği üzere Rize ili 2022 yılındaki yapı alanları sınıflandırmasında %89 ile en düşük üretici doğruluğu, %99 ile en yüksek üretici doğruluğu vejetasyon alanları sınıflandırılmasında elde edilmiştir. Su alanları sınıflandırmasında %97 ile en düşük kullanıcı doğruluğu ve boş alan sınıflandırmasında %98 ile en yüksek kullanıcı doğruluğu elde edilmiştir. Alan bazlı hata matrisinde toplam 58560000 m² alanda 522706 m²'si boş alan, 9401126 m²'si yapı alanları, 29108897 m²'si vejetasyon alanları ve 19527272 m²'si su alanları olarak elde edilmiştir.

Tablo 4.23: Rize ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi					
Sınıflar	Boş alan	Yapı alanı	Vejetasyon alanı	Su alanı	Alan
Boş alan	0.0083	0.0001	0.0001	0	492300
Yapı alanı	0.0006	0.1431	0.0014	0.0018	8610300
Vejetasyon alanı	0	0.0074	0.4956	0	29453600
Su alanı	0	0.01	0	0.3316	20003800
Toplam	0.0089	0.1605	0.4971	0.3335	58560000
Alan	522706	9401126	29108897	19527272	58560000
ÜD [%]	92.97	89.16	99.7	99.45	
KD [%]	98.71	97.35	98.53	97.08	

İkinci çalışma alanı olarak Yalova ili 2016 yılı görüntüsü eCognition yazılımında ESP-2 parametresi çalıştırıldı. Yalova ili 2016 yılı için görüntüde ESP-2 kullanılarak elde edilen ölçek parametreleri sonucunda LV (Local variance) grafiği Şekil 4.41’de gösterilmiştir.



Şekil 4.41: Yalova ili 2016 yılı ESP-2 parametresi LV grafiği.

Yalova ili 2016 yılı görüntüsünde eCognition yazılımında ESP-2 parametresi ile ölçek değerleri L1 104, L2 284 ve L3 684 ölçek değerleri elde edilmiştir. L1 değeri 104 olan ölçek parametresi için segmentasyon sonucu Şekil 4.42’de elde edilmiştir.



Şekil 4.42: Yalova ili 2016 yılı için L1 değeri 104 olan ölçek parametresi için segmentasyon sonucu.

L2 değeri 284 olan ölçek parametresi için segmentasyon sonucu Şekil 4.43’de elde edilmiştir.



Şekil 4.43: Yalova ili 2016 yılı için L2 değeri 284 olan ölçek parametresi için segmentasyon sonucu.


L3 değeri 684 olan ölçek parametresi için segmentasyon sonucu Şekil 4.44’de elde edilmiştir.



Şekil 4.44: Yalova ili 2016 yılı için L3 değeri 684 olan ölçek parametresi için segmentasyon sonucu.


Şekil 4.42, Şekil 4.43 ve Şekil 4.44’den de görüleceği üzere L1 seviyesinden L3 seviyesine doğru görüntüdeki görüntü nesne sayısı azalmaktadır. L3 seviyesinde 21 segment elde edilmiş ve L2 seviyesindeki görüntüde 121 segment üretilmiştir. L1 seviyesinde 691 segment üretilmiştir. L1 seviyesi sonucu oluşan görüntüde ölçek parametresi Yalova ili 2016 yılı için en iyi ölçeği göstermektedir.

Görüntü bölütleme işleminde Ölçek 104, Şekil 0.1, Kompaktlık 0.5 ve Görüntü Katmanı Ağırlıkları 1,1,1,1 olarak parametreler kullanıldığı Şekil 4.45’de gösterilmiştir.



Şekil 4.45: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon parametreleri.


Seçilen parametreler sonucunda Yalova ili 2016 yılı için segmentasyon görüntüsü oluşturulmuştur. Oluşturulan segmentasyon görüntüsü Yalova ili 2016 yılı için Şekil 4.46’da gösterilmiştir.



Şekil 4.46: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon haritası.

Yapılan segmentasyon sonucu Yalova ili 2016 yılı 669 segment elde edilmiştir. Şekil 4.46’da gösterilen segmentasyon haritasında minimum segment alanı 399.945 m² ve maksimum segment alanı 382223.976 m² olarak elde edilmiştir.

Segmentasyon kalitesinin değerlendirilmesi için Yalova ili 2016 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2016 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.47’de gösterilmiştir.



Şekil 4.47: Yalova ili 2016 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Yalova ili 2016 yılı segmentasyon kalite metrikleri Tablo 4.24’de gösterilmiştir.

Tablo 4.24’den de görüleceği üzere bu çalışmada bütün referans alanları için görüntüde çok segmentasyonu ifade etmektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 2 numaralı referans alanının

değerleri sırasıyla 0.003 ve 0.996 olarak hesaplanırken, 4 numaralı referans alanının değerleri sırasıyla 0.001 ve 0.998 olarak hesaplanmıştır.

Tablo 4.24: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri.


Referans alan	Ar	As	Quality Rate (Qr)	Area Fit İndex (AFI)
1	22718.326	22396.842	0.985849133	0.014150867
2	10536.369	10498.497	0.996405593	0.003594407
3	4530.489	4499.365	0.993130101	0.006869899
4	15921.669	15897.633	0.998490359	0.001509641
5	3863.216	3799.422	0.983486815	0.016513185

Sınıflandırma öncesinde segmentlere ait öznitelikler seçildi. Kullanılan Kırmızı, Yeşil ve Mavi bantları için parlaklık, ortalama katman ve maksimum fark öznitelikleri kullanıldı. Oluşturulan her segment için bu öznitelikler kullanıldı. Yalova ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri Şekil 4.48’de gösterilmiştir.

	Max_diff	Mean_Layer	Mean_Layer_1	Mean_Layer_2	Class_name	Brightness
1	0.69314517730...	1264.25352112...	991.035211267...	849.552816901...	3	930.952464788...
2	0.65642487406...	1334.05882352...	1161.07843137...	884.696078431...	3	1012.34150326...
3	0.69661749133...	1080.23111111...	778.044444444...	722.971111111...	3	779.598888888...
4	0.51777462841...	1591.67511885...	1412.02694136...	1125.96196513...	1	1266.40649762...
5	0.41445640057...	1959.94230769...	2017.75000000...	1582.26923076...	1	1716.56730769...
6	0.64237731228...	1654.33454545...	1368.15636363...	1062.22909090...	1	1236.23181818...
7	0.68844622632...	1464.24625267...	1149.52462526...	928.927194860...	3	1067.93254817...
8	0.64021284767...	1570.15789473...	1330.42982456...	1013.83333333...	1	1181.96710526...
9	0.55974320411...	1641.64705882...	1535.47058823...	1155.70588235...	1	1310.26470588...
10	0.44540497746...	1970.82528349...	1923.44225115...	1488.10037799...	1	1654.11098278...
11	0.64817974431...	1661.75978407...	1378.64507422...	1079.15789473...	1	1243.78205128...
12	0.64341159043...	1617.31860465...	1337.72093023...	1044.49069767...	1	1209.63837209...
13	0.23190200116...	2331.50000000...	2940.25000000...	2666.00000000...	1	2625.03125000...
14	0.71473349099...	1520.38602329...	1263.83693843...	965.625623960...	3	1117.82237936...
15	0.40027587936...	2643.67647058...	2750.44117647...	2176.02941176...	1	2345.44117647...
16	0.76452600973...	1340.54516129...	924.651612903...	841.232258064...	2	933.350806451...
17	0.43473991052...	1907.01680672...	1878.81512605...	1479.24369747...	1	1617.25210084...
18	0.66410038179...	1563.51944444...	1250.77638888...	1026.16041666...	1	1158.63194444...
19	0.77470084220...	1266.05128205...	850.903846153...	805.339743589...	3	877.195512820...

Şekil 4.48: Yalova ili 2016 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Segmentasyon yapıldıktan sonra sınıflandırma işlemine geçildi. Yalova ili 2016 yılı için üç sınıf oluşturuldu. Bu sınıflar boş alan, yapı alanları ve vejetasyon alanları olarak oluşturuldu. Daha sonra segmentler üzerinden sınıflar için örnek seçimi yapıldı. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir. Örnek seçimleri yapıldıktan sonra standart en yakın komşu özelliğinden temel sınıflandırma işlemi yapıldı ve bunun sonucunda sınıflandırma haritası elde edilmiştir. Oluşturulan sınıflandırma haritası Yalova ili 2016 yılı için Şekil 4.49’da gösterilmiştir.



Şekil 4.49: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.

Oluşturulan sınıflandırma sonucu tematik haritanın genel doğruluğu %98.66 ve Kappa sınıflandırması 0.9772 olarak elde edilmiştir. Sınıflandırma sonucunda oluşturulan Şekil 4.49’daki tematik haritada gösterilen üç sınıf için alan hesaplanması yapılmıştır. Yapı alanları 4351272.106 m², vejetasyon alanları 16271679.539 m² ve boş alan 9092407.900 m² olarak elde edilmiştir. Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi Tablo 4.25’de gösterilmiştir.

Tablo 4.25: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Toplam
Yapı alanları	5952	0	36	5988
Vejetasyon	77	5338	0	5415
Boş alan	0	56	3595	3651
Toplam	6029	5394	3631	15054

Referans veride hata matrisinde yapı alanı olarak sınıflandırılması gereken 36 piksel boş alan olarak sınıflandırılmıştır. Vejetasyon alanları olarak sınıflandırılması gereken 77 piksel yapı alanları olarak sınıflandırılmıştır. Boş alan olarak sınıflandırılması gereken 56 piksel vejetasyon alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 15054 piksel sayısında 6029'u yapı alanı, 5394'ü vejetasyon alanları ve 3631'i boş alan olarak sınıflandırılmıştır.


Sınıflandırma sonucu Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.26'da gösterilmiştir.

Tablo 4.26'dan de görüleceği üzere Yalova ili 2016 yılındaki yapı alanları sınıflandırmasında %94 ile en düşük üretici doğruluğu, %99.71 ile en yüksek üretici doğruluğu boş alanları sınıflandırılmasında elde edilmiştir. Boş alanları sınıflandırmasında %98.47 ile en düşük kullanıcı doğruluğu ve yapı alanları sınıflandırmasında %99 ile en yüksek kullanıcı doğruluğu elde edilmiştir. Alan bazlı hata matrisinde toplam 29720200 m²'lik alanda 4557154 m²'si yapı alanları, 16182467 m²'si vejetasyon alanlarını ve 8980579 m²'si boş alan olarak elde edilmiştir.

Tablo 4.26: Yalova ili 2016 yılı çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Alan
Yapı alanları	0.1455	0	0.0009	4351900
Vejetasyon	0.0078	0.5398	0	16274400
Boş alan	0	0.0047	0.3013	9093900
Toplam	0.1533	0.5445	0.3022	29720200
Alan	4557154	16182467	8980579	29720200
ÜD [%]	94.92	99.14	99.71	
KD [%]	99.4	98.58	98.47	

İkinci çalışma alanı olarak Yalova ili 2022 yılı görüntüsü eCognition yazılımında ESP-2 parametresi çalıştırıldı. Yalova ili 2022 yılı için görüntüde ESP-2 kullanılarak elde edilen ölçek parametreleri sonucunda LV (Local variance) grafiği Şekil 4.50’de gösterilmiştir.



Şekil 4.50: Yalova ili 2022 yılı ESP-2 parametresi LV grafiği.

Yalova ili 2022 yılı görüntüsünde eCognition yazılımında ESP-2 parametresi ile ölçek değerleri L1 99, L2 249 ve L3 549 ölçek değerleri elde edilmiştir. L1 değeri 99 olan ölçek parametresi için segmentasyon sonucu Şekil 4.51’de elde edilmiştir.



Şekil 4.51: Yalova ili 2022 yılı için L1 değeri 99 olan ölçek parametresi için segmentasyon sonucu.

L2 değeri 249 olan ölçek parametresi için segmentasyon sonucu Şekil 4.52’de elde edilmiştir.



Şekil 4.52: Yalova ili 2022 yılı için L2 değeri 249 olan ölçek parametresi için segmentasyon sonucu.


L3 değeri 549 olan ölçek parametresi için segmentasyon sonucu Şekil 4.53’de elde edilmiştir.



Şekil 4.53: Yalova ili 2022 yılı için L3 değeri 549 olan ölçek parametresi için segmentasyon sonucu.


Şekil 4.51, Şekil 4.52 ve Şekil 4.53'den de görüleceği üzere L1 seviyesinden L3 seviyesine doğru görüntüdeki görüntü nesne sayısı azalmaktadır. L3 seviyesinde 42 segment elde edilmiş ve L2 seviyesindeki görüntüde 193 segment üretilmiştir. L1 seviyesinde 857 segment üretilmiştir. L1 seviyesi sonucu oluşan görüntüde ölçek parametresi Yalova ili 2022 yılı için en iyi ölçeği göstermektedir.

Görüntü bölütleme işleminde Ölçek 99, Şekil 0.1, Kompaktlık 0.5 ve Görüntü Katmanı Ağırlıkları 1,1,1,1 olarak parametreler kullanıldığı Şekil 4.54'de gösterilmiştir.



Şekil 4.54: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon parametreleri.

Seçilen parametreler sonucunda Yalova ili 2022 yılı için segmentasyon görüntüsü oluşturulmuştur. Oluşturulan segmentasyon görüntüsü Yalova ili 2022 yılı için Şekil 4.55’de gösterilmiştir.



Şekil 4.55: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon haritası.

Yapılan segmentasyon sonucu Yalova ili 2022 yılı 857 segment elde edilmiştir. Şekil 4.55’de gösterilen segmentasyon haritasında minimum segment alanı 399.937 m² ve maksimum segment alanı 504812.248 m² olarak elde edilmiştir.

Segmentasyon kalitesinin değerlendirilmesi için Yalova ili 2022 yılı görüntüde AFI ve Qr metriklerini hesaplamak için ilk önce bazı alanlar elle sayısallaştırıldı. 2022 yılı görüntüdeki elle sayısallaştırılan nesneler Şekil 4.56’da gösterilmiştir.



Şekil 4.56: Yalova ili 2022 yılı segmentlerin referans nesnelerle olan örtüşme alanları.

Görüntüde referans nesnesi olarak 5 alan dikkatli bir şekilde sayısallaştırılmıştır. Referans objesi olarak seçilen nesnelerin alanları hesaplandı ve segmentasyon kalitesini ölçmek için toplam referans alanları ve ele alınan segmentlerin toplam alanları hesaplandı. Yalova ili 2022 yılı segmentasyon kalite metrikleri Tablo 4.27’de gösterilmiştir.

Tablo 4.27’den de görüleceği üzere bu çalışmada bütün referans alanları için görüntüde çok segmentasyonu ifade etmektedir. Qr sonuçları referans alanları için 1’e yakın olarak elde edilmiştir. Örneğin, AFI ve Qr değerleri 1 numaralı referans alanının değerleri sırasıyla 0.004 ve 0.996 olarak hesaplanırken, 4 numaralı referans alanının değerleri sırasıyla 0.012 ve 0.988 olarak hesaplanmıştır.

Tablo 4.27: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu kalite metrikleri.

Referans alan	Ar	As	Quality Rate (Qr)	Area Fit Index (AFI)
1	41565.776	41392.69	0.995835853	0.004164147
2	61367.518	59188.472	0.964491867	0.035508133
3	54375.03	49191.479	0.904670379	0.095329621
4	4452.285	4399.379	0.988117113	0.011882887
5	11509.467	10398.654	0.903487016	0.096512984


Sınıflandırma öncesinde segmentlere ait öznitelikler seçildi. Kullanılan Kırmızı, Yeşil ve Mavi bantları için parlaklık, ortalama katman ve maksimum fark öznitelikleri kullanıldı. Oluşturulan her segment için bu öznitelikler kullanıldı. Yalova ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri Şekil 4.57’de gösterilmiştir.

	Max_diff	Mean_Layer	Mean_Layer_1	Mean_Layer_2	Class_name	Brightness
1	0.76372231651...	1462.02506963...	1128.57103064...	884.738161559...	3	1036.44986072...
2	0.87684387836...	1483.97422680...	1107.79896907...	841.657216494...	3	1008.31701030...
3	0.87857543881...	1238.92280701...	853.908771929...	708.091228070...	3	828.078947368...
4	0.60340593421...	1681.35692307...	1447.82153846...	1082.57846153...	1	1280.16384615...
5	0.52486317378...	1854.22826086...	1716.13043478...	1288.29347826...	1	1483.55434782...
6	0.72590688761...	1637.02816901...	1317.66901408...	943.950704225...	1	1171.34683098...
7	0.50337763930...	1847.16417910...	1700.07036247...	1315.58955223...	1	1489.99013859...
8	0.70450483216...	1537.63733333...	1243.93866666...	923.850666666...	1	1114.47733333...
9	0.76125929029...	1605.74647887...	1285.90140845...	905.042253521...	1	1134.66549295...
10	0.90735572555...	1205.57894736...	830.771929824...	691.315789473...	3	801.500000000...
11	0.84878687445...	1110.18181818...	715.777777777...	636.373737373...	3	736.785353535...
12	0.63541201404...	1440.34422110...	1180.27889447...	899.939698492...	3	1070.21922110...
13	0.73951797427...	1525.12707182...	1206.17679558...	893.408839779...	1	1086.57458563...
14	0.51637661374...	1899.67349726...	1759.52049180...	1328.90300546...	1	1525.06557377...
15	0.44436503937...	2165.43478260...	2094.94927536...	1595.76086956...	1	1804.88768115...
16	0.69623477468...	1525.31818181...	1227.29545454...	907.431818181...	1	1104.15340909...
17	0.54178407969...	1726.54786150...	1564.52545824...	1166.79022403...	1	1361.67006109...
18	0.69201573390...	1430.81632653...	1136.46938775...	858.46938775...	1	1035.07142857...
19	0.81042405661...	1596.10937500...	1195.15625000...	883.515625000...	1	1095.72265625...

Şekil 4.57: Yalova ili 2022 yılı görüntüsünde oluşan segmentlere ait öznitelik bilgileri.

Segmentasyon yapıldıktan sonra sınıflandırma işlemine geçildi. Yalova ili 2022 yılı için üç sınıf oluşturuldu. Bu sınıflar boş alan, yapı alanları ve vejetasyon alanları olarak oluşturuldu. Daha sonra segmentler üzerinden sınıflar için örnek seçimi

yapıldı. Eğitim ve test verileri seçilirken görüntüde homojen olacak şekilde ve her sınıf sayısında eşit olacak şekilde veri seçilmiştir. Örnek seçimleri yapıldıktan sonra standart en yakın komşu özelliğinden temel sınıflandırma işlemi yapıldı ve bunun sonucunda sınıflandırma haritası elde edilmiştir. Oluşturulan sınıflandırma haritası Yalova ili 2022 yılı için Şekil 4.58’de gösterilmiştir.



Şekil 4.58: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritası.

Oluşturulan sınıflandırma sonucu tematik haritanın genel doğruluğu %97.87 ve Kappa sınıflandırması 0.9663 olarak elde edilmiştir. Sınıflandırma sonucunda oluşturulan Şekil 4.58’deki tematik haritada gösterilen üç sınıf için alan hesaplanması yapılmıştır. Yapı alanları 8709019.228 m², vejetasyon alanları 14341930.510 m² ve boş alan 6664410.907 m² olarak elde edilmiştir. Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi Tablo 4.28’de gösterilmiştir.

Tablo 4.28: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyonu sonucu oluşan sınıflandırma haritasının hata matrisi.

Hata Matrisi (piksel sayısı)				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Toplam
Yapı alanları	4472	18	15	4505
Vejetasyon	158	7244	0	7402
Boş alan	0	126	3088	3214
Toplam	4630	7388	3103	15121

Referans veride hata matrisinde yapı alanı olarak sınıflandırılması gereken 33 pikselin 18'i vejetasyon alanı ve 15'i boş alan olarak sınıflandırılmıştır. Vejetasyon alanları olarak sınıflandırılması gereken 158 piksel yapı alanları olarak sınıflandırılmıştır. Boş alan olarak sınıflandırılması gereken 126 piksel vejetasyon alanları olarak sınıflandırılmıştır. Hata matrisinde toplam 15121 piksel sayısında 4630'u yapı alanı, 7388'i vejetasyon alanları ve 3103'ü boş alan olarak sınıflandırılmıştır.

Sınıflandırma sonucu Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi Tablo 4.29'da gösterilmiştir.

Tablo 4.29'dan de görüleceği üzere Yalova ili 2022 yılındaki yapı alanları sınıflandırmasında %96 ile en düşük üretici doğruluğu, %99 ile en yüksek üretici doğruluğu boş alanları sınıflandırılmasında elde edilmiştir. Boş alanları sınıflandırmasında %96 ile en düşük kullanıcı doğruluğu ve yapı alanları sınıflandırmasında %99 ile en yüksek kullanıcı doğruluğu elde edilmiştir. Alan bazlı hata matrisinde toplam 29720200 m²'lik alanda 8952782 m²'si yapı alanları, 14334226 m²'si vejetasyon alanı ve 6433192 m²'si boş alan olarak elde edilmiştir.

Tablo 4.29: Yalova ili 2022 yılı çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma haritasının alan bazında hata matrisi.

Alan Bazlı Hata Matrisi				
Sınıflar	Yapı alanları	Vejetasyon	Boş alan	Alan
Yapı alanları	0.14550	0.0012	0.001	8710400
Vejetasyon	0.0103	0.4723	0	14344300
Boş alan	0	0.0088	0.2155	6665500
Toplam	0.3012	0.4823	0.2165	29720200
Alan	8952782	14334226	6433192	29720200
ÜD [%]	96.58	97.93	99.55	
KD [%]	99.27	97.86	96.08	

4.3. Değişim Tespiti Analizi

Değişim tespiti analizinde farklı zamanlardaki görüntüler sınıflandırılarak aralarındaki sınıfsal dağılımlara bakarak değişimin nasıl gerçekleştiği analiz edilmiştir. Üretilen sınıfların alansal dağılımı ve değişim oranları hesaplanmıştır. Sınıflandırma da Rize ve Yalova illerinde 2016 ve 2022 yılları arasındaki değişimi ortalama kaydırma ve çoklu çözünürlüklü segmentasyon sonucu oluşan sınıflandırma sonuçlarına dayalı alansal sınıf dağılımları tespit edilmiştir. Rize ilinde 1 numaralı sınıf boş alanı, 2 numaralı sınıf yapı alanını, 3 numaralı sınıf vejetasyon alanını ve 4 numaralı sınıf su alanını temsil etmektedir. Yalova ilinde 1 numaralı alan yapı alanını, 2 numaralı alan vejetasyon alanını ve 3 numaralı alan ise boş alanı temsil etmektedir. Rize ve Yalova illerindeki yıllara göre sınıfların alansal değişimi sırasıyla aşağıda tablolar halinde verilmiştir.

Rize ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki sınıf bazında alansal değişimi Tablo 4.30’da gösterilmiştir.

Tablo 4.30’dan da görüleceği üzere Rize ilinde 29000 m² boş alan değişim olmayan alan olarak değişim matrisinden elde edilmiştir. Bu değişim matrisinden şu anlaşılmaktadır; 2016 yılı görüntüsünde boş olan alanlar ile 2022 yılı görüntüsündeki çalışma alanında aynı yerlerde boş alan olduğu görülmektedir. 2016 yılında boş alan iken 98400 m²’si yapı alanı olmuştur ve boş alanda azalma görülmüştür. 2016 yılında


boş alan iken 149200 m²'si vejetasyon alanı olmuştur. Boş alandan su alanına herhangi bir değişim görülmemiştir. 2016 yılında yapı alanı iken 45700 m²'lik boş alanda artış görülmektedir. 2016 yılında vejetasyon alanı iken 2760000 m²'lik alan ve su alanı iken 27100 m²'lik boş alanda artış görülmektedir. Su alanı iken 2661900 m²'lik alan yapı alanı, 3900 m²'lik alan vejetasyon alanı olarak elde edilmiştir. Rize ilinde 20082500 m²'lik su alanında bir değişim görülmemiştir.

Tablo 4.30: Rize ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.

Yeni Sınıf	Referans Sınıf	Alan (m2)	Açıklama
1	1	29000	Boş alanda değişim yok
1	2	45700	Boş alanda artış, yapı alanında azalma
1	3	276000	Boş alanda artış, vejetasyon alanında azalma
1	4	27100	Boş alanda artış, su alanında azalma
2	1	98400	Yapı alanında artış, boş alanda azalma
2	2	3677200	Yapı alanında değişim yok
2	3	1789500	Yapı alanında artış, vejetasyon alanında azalma
2	4	2661900	Yapı alanında artış, su alanında azalma
3	1	149200	Vejetasyon alanında artış, boş alanda azalma
3	2	2726200	Vejetasyon alanında artış, yapı alanında azalma
3	3	26800500	Vejetasyon alanında değişim yok
3	4	3900	Vejetasyon alanında artış, su alanında azalma
4	2	160900	Su alanında artış, yapı alanında azalma
4	3	32000	Su alanında artış, vejetasyon alanında azalma
4	4	20082500	Su alanında değişim yok

Rize ili ortalama kayma segmentasyonu değişim tespiti tematik haritası Şekil 4.59'da gösterilmiştir.

Şekil 4.59'da görüleceği üzere havalimanının denize doldurma ile yapıldığından su alanında azalma ve yapı alanında artışı göstermektedir. Havalimanı yapıldığından dolayı yeni yollar yapıldığı ve bundan dolayı vejetasyon alanında azalma ve yapı alanında artış görülmektedir.



Şekil 4.59: Rize ili ortalama kayma segmentasyonu değişim tespiti tematik haritası.

Rize ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki sınıf bazında alansal değişimi Tablo 4.31’de gösterilmiştir.


Tablo 4.31’den da görüleceği üzere Rize ilinde 52100 m² boş alan değişim olmayan alan olarak değişim matrisinden elde edilmiştir. Boş alanda 127200 m²’lik artış yapı alanından, 312900 m²’lik artış vejetasyon alanından ve 100 m²’lik alan su alanında gelmektedir. Yapı alanında 41000 m²’lik artış boş alandan, 1706100 m²’lik artış vejetasyon alanından ve 3007100 m²’lik artış su alanından gelmektedir. Vejetasyon alanında 133900 m²’lik artış boş alandan, 1444200 m²’lik artış yapı alanından ve 22900 m²’lik artış su alanından gelmektedir. Su alanında 101600 m²’lik artış yapı alanından gelmektedir. Su alanlarında artış boş alan ve vejetasyon alanından gelmediği görülmektedir.

Tablo 4.31: Rize ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.

Yeni Sınıf	Referans Sınıf	Alan (m2)	Açıklama
1	1	52100	Boş alanda değişim yok
1	2	127200	Boş alanda artış, yapı alanda azalma
1	3	312900	Boş alanda artış, vejetasyon alanında azalma
1	4	100	Boş alanda artış, su alanında azalma
2	1	41000	Yapı alanında artış, boş alanda azalma
2	2	3856100	Yapı alanında değişim yok
2	3	1706100	Yapı alanında artış, vejetasyon alanında azalma
2	4	3007100	Yapı alanında artış, su alanında azalma
3	1	133900	Vejetasyon alanında artış, boş alanda azalma
3	2	1444200	Vejetasyon alanında artış, yapı alanında azalma
3	3	27852600	Vejetasyon alanında değişim yok
3	4	22900	Vejetasyon alanında artış, su alanında azalma
4	2	101600	Su alanında artış, yapı alanında azalma
4	4	19902200	Su alanında değişim yok

Rize ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası Şekil 4.60'da gösterilmiştir.

Rize ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritasından da görüleceği üzere havalimanı yapıldığından dolayı su alanında azalma, yapı alanında artış görülmektedir. Şekil 4.60'dan da görüleceği üzere havalimanı bölgesinin tamamı yapı alanı olarak sınıflandırılmıştır. 2016 yılı görüntüsünde dere havzasında fazla su olmadığından ve 2022 yılı görüntüsünde dere havzasında su artışı olduğundan değişim tespiti haritasında yapı alanında azalma, su alanında artış görülmektedir. Yeni yollar yapıldığından dolayı yeşil alanlarda azalma yapı alanında artış görülmektedir.



Şekil 4.60: Rize ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası.

Yalova ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki sınıf bazında alansal değişimi Tablo 4.32’de gösterilmiştir.


Yalova ili değişim matrisinde 3625200 m²’lik alan yapı alanlarında değişim olmadığı, 13608000 m²’lik alan vejetasyon alanlarında değişimin olmadığı ve 648900 m²’lik alan ise boş alanlarda değişimin olmadığı elde edilmiştir. 2368700 m²’lik alan yapı alanlarında artışı, vejetasyon alanlarında azalmayı göstermektedir. 685100 m²’lik alan yapı alanlarında artışı, boş alanlarda azalmayı göstermektedir. Vejetasyon alanında 1477400 m²’lik artış yapı alanlarından ve 3036900 m²’lik artış boş alanlardan geldiği görülmektedir. 1376800 m²’lik alan boş alanlarında artışı, yapı alanlarında azalmayı göstermektedir. 2893200 m²’lik alan boş alanlarında artışı, vejetasyon alanlarında azalmayı göstermektedir.

Tablo 4.32: Yalova ili ortalama kayma segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.

Yeni Sınıf	Referans Sınıf	Alan (m2)	Açıklama
1	1	3625200	Yapı alanlarında değişim yok
1	2	2368700	Yapı alanlarında artış, vejetasyon alanlarında azalma
1	3	685100	Yapı alanlarında artış, boş alanlarda azalma
2	1	1477400	Vejetasyon alanlarında artış, yapı alanlarında azalma
2	2	13608000	Vejetasyon alanlarında değişim yok
2	3	3036900	Vejetasyon alanlarında artış, boş alanda azalma
3	1	1376800	Boş alanda artış, yapı alanlarında azalma
3	2	2893200	Boş alanda artış, vejetasyon alanında azalma
3	3	648900	Boş alanlarda değişim yok

Yalova ili ortalama kayma segmentasyonu değişim tespiti tematik haritası Şekil 4.61’de gösterilmiştir.

Şekil 4.61’den de görüleceği üzere vejetasyon alanında sanayi bölgesi yapıldığından dolayı yapı alanında artış görülmektedir. Boş alanların yani tarım ekili olmayan alanların vejetasyon alana dönüştüğü görülmektedir. Yeşil alanların boş alanlara dönüştüğü görülmektedir. Bu artışın yoğun olduğu bölge yeni sanayi bölgesinin yapıldığı alana doğru bir artış görülmektedir.



Şekil 4.61: Yalova ili ortalama kayma segmentasyonu değişim tespiti tematik haritası.

Yalova ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki sınıf bazında alansal değişimi Tablo 4.33’de gösterilmiştir.


Tablo 4.33’den de görüleceği üzere 3098800 m²’lik yapı alanlarında değişim olmadığı, 10088500 m²’lik vejetasyon alanlarında değişimin olmadığı ve 2618900 m²’lik boş alanlarda değişim olmadığı değişim matrisinden elde edilmiştir. Yapı alanlarındaki artış 3165100 m²’lik alan vejetasyon alanlarından ve 2446500 m²’lik alan boş alanlardan gelmektedir. Vejetasyon alanlarındaki artış 227300 m²’lik alan yapı alanlarından ve 4028500 m²’lik alan boş alanlardan geldiği görülmektedir. Boş alanlardaki artış 1025800 m²’lik alan yapı alanlarından ve 3020800 m²’lik alan vejetasyon alanlarından geldiği görülmektedir.

Tablo 4.33: Yalova ili çoklu çözünürlüklü segmentasyonu sonucu 2016-2022 sınıflandırma haritaları arasındaki alansal değişim.

Yeni Sınıf	Referans Sınıf	Alan (m2)	Açıklama
1	1	3098800	Yapı alanlarında değişim yok
1	2	3165100	Yapı alanlarında artış, vejetasyon alanlarında azalma
1	3	2446500	Yapı alanlarında artış, boş alanlarda azalma
2	1	227300	Vejetasyon alanlarında artış, yapı alanlarında azalma
2	2	10088500	Vejetasyon alanlarında değişim yok
2	3	4028500	Vejetasyon alanlarında artış, boş alanlarda azalma
3	1	1025800	Boş alanlarda artış, yapı alanlarında azalma
3	2	3020800	Boş alanlarda artış, vejetasyon alanlarında azalma
3	3	2618900	Boş alanlarda değişim yok

Yalova ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası Şekil 4.62’de gösterilmiştir.

Çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritasında yeşil alanda azalma boş alanda artış görülmektedir. Şekil 4.63’deki tematik haritada bu değişim mor rengi ile gösterilmektedir. Bunun sebebi o bölgede yeni sanayi bölgesi kurulmasından dolayı yeni yeni yapılaşmalar olacağı düşünüldüğünden yeşil alanda azalma boş alanda artış görülmektedir. Yine yeni sanayi bölgesi kurulacak alanda yeşil alanlarda azalma yapı alanlarında artış görülmektedir. Yeni sanayi bölgesinin dışında şehirleşmenin olduğu bölgede boş alanlarda azalma yapı alanlarında artış görülmektedir. Tematik haritada görülen mavi renkli değişim şehir alanı iken yeşil alana dönüştüğü görülmektedir.



Şekil 4.62: Yalova ili çoklu çözünürlüklü segmentasyonu değişim tespiti tematik haritası.

5. BULGULAR VE TARTIŞMA

Bu bölümde, çalışmanın nihai sınıflandırma sonuçları açıklanmış ve elde edilen sonuçlar hakkında ayrıntılı bir tartışma içermektedir. 2016 ve 2022 yılları arasındaki çalışma alanlarında vejetasyon olan ve olmayan, orman alanları ve orman olmayan alanlarının değişiklikleri analiz edilmektedir. İlk olarak segmentasyon algoritmaları açısından sonuçların analizi yapılmıştır. Daha sonra değişim tespiti sonuçlarının analizi yapılmıştır.

5.1. Segmentasyon Algoritmaları Açısından Sonuçların Analizi

Nesne tabanlı sınıflandırması yapılmış olan iki farklı yıla ait iki çalışma bölgesindeki görüntülere ortalama kayma ve çoklu çözünürlüklü segmentasyon uygulanmıştır. Segmentlerin destek vektör makineleri ve en yakın komşuluk algoritmasıyla görüntünün özellikleri kullanılarak sınıflandırma yapılmıştır. Sınıflandırma sonucunda kullanıcı doğruluğu ve üretici doğruluğun harmonik ortalaması olan F-Skor ve genel doğruluk hesaplanmıştır. Rize ve Yalova illerinin 2016 ve 2022 yıllarına ait görüntülerde oluşan sınıflara göre F-skor ve genel doğruluk Tablo 5.1’de gösterilmiştir.

Tablo 5.1’de Rize ilinde 1. sınıf boş alanı, 2. sınıf yapı alanını, 3. sınıf vejetasyon alanını ve 4. sınıf su alanını temsil etmektedir. Yalova ilinde 1. sınıf yapı alanlarını, 2. sınıf vejetasyon alanlarını ve 3. sınıf boş alanları temsil etmektedir. Tablo 5.1’den de görüleceği üzere Rize ili 2016 yılı görüntüsünde ortalama kayma segmentasyonu ile yapılan sınıflandırmada en düşük F-skor yapı alanlarında %79 ile görülmektedir. En yüksek F-skor %97 ile su alanlarında görülmüştür. Çoklu çözünürlüklü segmentasyonu ile yapılan sınıflandırmada en düşük F-skor %94 ile yapı alanında, en yüksek F-skor %98 ile vejetasyon alanında görülmektedir. İki segmentasyon algoritmasında su alanlarında F-skor çok yakın sonuç verdiği görülmektedir. Rize ili 2016 yılı görüntüsünde ortalama kayma algoritması ile genel doğruluk %94, çoklu çözünürlük algoritması ile %97 genel doğruluk görülmektedir.

Rize ili 2022 yılı görüntüsünde ortalama kayma algoritması ile en düşük F-skor %74 ile boş alanlarda, en yüksek F-skor %95 ile su alanında görülmüştür. Çoklu çözünürlük algoritması ile en düşük F-skor %93 ile yapı alanında görülürken, en

yüksek F-skor %99 ile vejetasyon alanında görülmüştür. Rize ili 2022 yılı görüntüsünde ortalama kayma algoritması ile genel doğruluk %93, çoklu çözünürlük algoritması ile %97 genel doğruluk görülmektedir.

Yalova ili 2016 yılı görüntüsünde ortalama kayma algoritması ile en düşük F-skor %69 ile yapı alanını, en yüksek F-skor %89 ile vejetasyon alanında görülmektedir. Çoklu çözünürlük algoritması ile en düşük F-skor %97 ile yapı alanını, en yüksek F-skor %99 ile boş alanlarda görülmektedir. Yalova ili 2016 yılı görüntüsünde ortalama kayma algoritması ile genel doğruluk %84, çoklu çözünürlük algoritması ile %98 genel doğruluk elde edilmiştir.

Yalova ili 2022 yılı görüntüsünde ortalama kayma algoritması ile en düşük F-skor %86 ile boş alanlarda iken en yüksek F-skor %97 ile vejetasyon alanında elde edilmiştir. Çoklu çözünürlük algoritması ile en düşük F-skor %97.89 ile vejetasyon alanında ve en yüksek F-skor %97.91 ile yapı alanında görülmektedir. Yalova ili 2022 yılı görüntüsünde ortalama kayma algoritması ile genel doğruluk %94, çoklu çözünürlük algoritması ile %97 genel doğruluk elde edilmiştir.

Segmentasyon algoritmaları açısından sonuçların analizinde Rize ve Yalova illerinde 2016 ve 2022 yılı görüntülerinde en yüksek genel doğruluk çoklu çözünürlüklü segmentasyonu ile yapılan sınıflandırmada görülmektedir.

Tablo 5.1: Segmentasyon algoritmaları açısından sonuçların analizi.

			Ortalama kayma		Çoklu çözünürlüklü	
			F-Skor (%)	GD (%)	F-Skor (%)	GD (%)
Rize	2016	1	80.28	94.78	96.37	97.68
		2	79.84		94.21	
		3	96.72		98.84	
		4	97.6		97.09	
	2022	1	74.31	93.08	95.75	97.87
		2	84.86		93.07	
		3	94.13		99.11	
		4	95.35		98.25	
Yalova	2016	1	69.78	84.3	97.11	98.66
		2	89.05		98.86	
		3	89.02		99.09	
	2022	1	91.23	94.52	97.91	97.87
		2	97.81		97.89	
		3	86.97		97.78	

5.2. Değişim Tespiti Sonuçlarının Analizi

Ortalama kayma ve çoklu çözünürlüklü algoritmaları ile elde edilen sınıfların 2016 ve 2022 yıllarına göre değişimi tablolarda gösterilmiştir. Rize ili ortalama kayma ve çoklu çözünürlüklü segmentasyonu sonucu elde edilen 2016 ve 2022 yıllarına göre değişimi Tablo 5.2’de gösterilmiştir.

Ortalama kayma algoritması ile Rize ili 2016 yılı görüntüsünde boş alan 0.28 km² elde edilirken 2022 yılı görüntüsünde 0.34 km²’lik alan elde edilmiştir. Boş alanda 0.06 km²’lik bir artış görülmektedir. Çoklu çözünürlüklü segmentasyon algoritması ile 0.26 km²’lik bir artış görülmektedir. Rize ili 2016 yılındaki ortalama kayma algoritması ile yapı alanları 6.61 km²’lik alan elde edilirken 2022 yılı görüntüsünde 8.23 km²’lik alan elde edilmiştir. Yapı alanlarında ortalama kayma ile 1.62 km²’lik bir artış görülmektedir. Çoklu çözünürlüklü segmentasyon ile yapı alanları 2016 yılı 5.53 km²’lik alan ve 2022 yılı 8.62 km²’lik alan elde edilmiştir. Yapı alanlarında çoklu çözünürlüklü segmentasyon ile 3.09 km²’lik bir artış görülmektedir. Ortalama kayma algoritması ile vejetasyon alanlarında 0.78 km²’lik bir artış görülmektedir. Çoklu çözünürlük algoritması ile 0.42 km²’lik azalma görülmektedir. Vejetasyon alanlarındaki bu farklılık 2016 yılı görüntüsünde ortalama kayma segmentasyonunda bazı vejetasyon alanlarının boş alan olarak sınıflandırılmıştır. Ortalama kayma algoritması ile su alanlarında 2.50 km²’lik bir azalma ve çoklu çözünürlük algoritmasında 2.93 km²’lik bir azalma görülmektedir.

Tablo 5.2: Rize ili deęişim tespiti sonuçlarının analizi.

Rize	Yıl	Ortalama Kayma			
		Boş Alan (km ²)	Yapı Alanları (km ²)	Vejetasyon (km ²)	Su Alanları (km ²)
	2016	0.28	6.61	28.90	22.78
	2022	0.34	8.23	29.68	20.28
	Deęişim Miktarı	0.06	1.62	0.78	2.50
	Yıl	Çoklu Çözünürlüklü			
		Boş Alan (km ²)	Yapı Alanları (km ²)	Vejetasyon (km ²)	Su alanları (km ²)
	2016	0.23	5.53	29.88	22.94
	2022	0.49	8.62	29.46	20.01
	Deęişim Miktarı	0.26	3.09	0.42	2.93

Yalova ili ortalama kayma ve çoklu çözünürlüklü segmentasyonu sonucu elde edilen 2016 ve 2022 yıllarına göre deęişimi Tablo 5.3’de gösterilmiştir.

Yalova ili 2016 yılı ortalama kayma algoritmasında yapı alanları 6.48 km²’lik alan elde edilirken, 2022 yılında yapı alanlarında 6.68 km²’lik alan elde edilmiştir. Çoklu çözünürlük algoritmasında 2016 yılı yapı alanları 4.35 km²’lik alan elde edilmiştir. 2022 yılı yapı alanları 8.71 km²’lik alan elde edilmiştir. Ortalama kayma algoritması ile 0.20 km²’lik bir artış görünürken, çoklu çözünürlük algoritması ile 4.36 km²’lik bir artış görülmektedir.

2016 yılı ortalama kayma algoritmasında vejetasyon alanlarında 18.87 km²’lik alan elde edilirken, 2022 yılında 18.12 km²’lik alan elde edilmiştir. Çoklu çözünürlük algoritmasında vejetasyon alanlarında 2016 yılında 16.27 km²’lik alan elde edilirken 2022 yılında 14.34 km²’lik alan elde edilmiştir. Ortalama kayma algoritması ile 0.75 km²’lik bir azalma görünürken, çoklu çözünürlük algoritması ile 1.93 km²’lik bir azalma görülmektedir.

2016 yılı ortalama kayma algoritmasında boş alanlarda 4.37 km²’lik alan elde edilirken, 2022 yılında 4.92 km²’lik alan elde edilmiştir. Çoklu çözünürlük algoritmasında boş alanlarda 2016 yılında 9.09 km²’lik alan elde edilirken, 2022 yılında 6.66 km²’lik alan elde edilmiştir. Ortalama kayma algoritması ile 0.55 km²’lik bir artış görülürken, çoklu çözünürlük ile 2.43’lük bir azalma görülmüştür.

Tablo 5.3: Yalova ili deęişim tespiti sonuçlarının analizi.

Yalova	Yıl	Ortalama Kayma		
		Yapı Alanları (km ²)	Vejetasyon (km ²)	Boş Alan (km ²)
	2016	6.48	18.87	4.37
	2022	6.68	18.12	4.92
	Deęişim Miktarı	0.20	0.75	0.55
	Yıl	Çoklu çözünürlüklü		
		Yapı Alanları (km ²)	Vejetasyon (km ²)	Boş Alan (km ²)
	2016	4.35	16.27	9.09
	2022	8.71	14.34	6.66
	Deęişim Miktarı	4.36	1.93	2.43

6. SONUÇLAR VE ÖNERİLER

Tez kapsamında, uzaktan algılanmış görüntüler yardımıyla arazi örtüsünde zaman içerisinde meydana gelen değişimlerin tespiti noktasında nesne tabanlı değişim analizinin kullanımı ele alınmış, yöntemin güçlü ve zayıf yönleri değerlendirilmiştir. İki çalışma bölgesinde 2016 ve 2022 yılları arasında meydana gelen değişimlerin tespitinde temel veri kaynağı olarak 10 metre mekânsal çözünürlüğe sahip Sentinel-2A görüntüleri kullanılmıştır. Bu çalışmada, iki bölgedeki 2016 ve 2022 görüntülerinin ortalama kayma segmentasyonu yöntemi ile elde edilen segmentlerin destek vektör makineleri yardımıyla sınıflandırılması sonucunda elde edilen genel doğruluklar %84-%94 arasındadır. Çoklu çözünürlüklü segmentasyonu sonucu en yakın komşuluk sınıflandırılması ile elde edilen genel doğruluk %97-%98 arasındadır. 2016 ile 2022 yılları arasında sınıflandırma sonrası değişiklik tespiti, vejetasyon alanlarında, yapı alanlarında ve diğer alanlarda bazı bölgelerde düşüş, bazı bölgelerde yükseliş görülmektedir. Görüntülerin segmentasyonu için pikselleri heterojen gruplara ayırmak için ortalama kayma ve çoklu çözünürlüklü segmentasyon algoritmaları kullanıldı.

Bu çalışmanın amacı, arazi örtüsü ve arazi kullanımındaki değişimi tespit edebilmek için multispektral uydu görüntülerini kullanarak nesne tabanlı bir değişim analizi yapmaktır. 2016 ve 2022 yıllarına ait dört çalışma bölgesi için iki adet uydu görüntüsü alınmıştır. Görüntüler coğrafi nesnelere bölünerek QGIS ve eCognition yazılımında iki sınıfta sınıflandırıldı. Sınıflandırılmış görüntülerin doğruluğu, referans görüntülere dayalı bir doğruluk değerlendirmesi ile kontrol edildi. Değişiklikleri algılamak ve değişiklikleri keşfetmek için QGIS'te tablolama yöntemi uygulandı. Nesne tabanlı bir değişiklik algılama yöntemi uygularken, her durum için mükemmel bir uyumun olmadığı sonucuna varılmıştır. Segmentasyon ve sınıflandırma sonuçları üzerinde her uydu görüntüsünün kendi etkisi vardır. Sonucu ayarlamak için birçok parametre uygulanabilir. Bu çalışmada iki segmentasyon yöntemi iki farklı yazılımda uygulanmıştır. Bu araştırmada eCognition yazılımında çoklu çözünürlüklü segmentasyon sonucu elde edilen segmentlerin en yakın komşu yöntemi sınıflandırılması sonucu yapılan değişiklik tespiti, diğer yöntemlere göre daha doğru sonuçlar vermiştir. Doğruluk değerlendirmesinde çoklu çözünürlüklü segmentasyon sonucu nesne tabanlı değişik tespiti daha yüksek doğruluklar elde edilmiştir. QGIS

yazılımında yapılan ortalama kayma segmentasyonu sonucu nesne tabanlı deęiřik tespitinde bazı sınıflarda çoklu çözünürlüklü segmentasyon algoritması ile benzer sonuçlar verdiği görölmüřtür.

Bu çalışma alanı için gelecekteki arařtırmalar yüksek çözünürlüklü görüntülerle yapılmalıdır. Örneęin, Sentinel 2A verilerinin uzaysal çözünürlüğü 10 metredir ve ücretsiz olarak kullanılabilir. Bu uydu 2016'dan beri mevcuttur. Yüksek çözünürlüklü görüntüler ile arazi örtüsü deęiřikliklerini daha doęru bir řekilde haritalamak ve arazi örtüsü dönüşümlerini daha hassas bir řekilde analiz etmek mümkündür.

eCognition'daki standart En Yakın Komřu Sınıflandırıcısı iki arazi sınıfıyla bu çalışma alanı için iyi çalışmasına raęmen, gelecekteki arařtırmalar uzaktan algılanan görüntüleri sınıflandırmak için daha iyi bir kural seti geliřtirmeye odaklanmalıdır. Ölçek parametresinin belirlenmesinde ESP-2 algoritması kullanılmıřtır ancak orta çözünürlüklü görüntü kullanıldığından dolayı görüntüdeki nesneler tam olarak algılanamadığından bazen iki sınıfı içeren özellikler tek bir sınıfta toplanmıřtır. Yüksek çözünürlüklü görüntü kullanarak bu sorunları daha aza indirerek daha iyi sonuçlar elde etmek mümkün olabilir.

Vejetasyon alanlarının ve su alanlarının azalması eğiliminin dięer bölgelerde de gerçekteřip gerçekteřmediğini arařtırmak için dünyamızın dięer bölgeleri için arazi örtüsü deęiřikliklerinin haritalanması ve analiz edilmesi de önerilir. Daha fazla arazi örtüsü deęiřim çalışması, artan nüfusla birlikte azalan tarım arazileri gibi zorluklarla daha iyi bir řekilde yüzleřmeye yardımcı olabilir. Deniz alanlarına doldurma ile yapı alanlarının artması, dünyamızın ekolojik yapısının bozulması ve su rezervlerinin azalması gibi sorunlara daha iyi bir řekilde yüzleřmeye yardımcı olabilir.

KAYNAKLAR

Antrop M., (2004), "Landscape change and the urbanization process in Europe", *Landscape and Urban Planning*, 67(1-4), 9-26.

Aydemir A., (2018), "Sulama Sonrası Harran Ovası Tarımsal Arazilerdeki Yapılaşmanın Piksel Tabanlı / Nesne Tabanlı Sınıflandırma Yöntemleri ile Belirlenmesi ve İki Yöntemin Karşılaştırılması" Yüksek Lisans Tezi, Harran Üniversitesi.

Baatz M., Schape A., (2000), "Multi Resolution Segmentation-an optimization Approach for high quality multi scale image segmentation", In Strobl j., T. Blaschke, G. Griesebner (Ed.), *Proceedings of Twelfth Angewandte Geographische Informationsverarbeitung*, (pp.12-23). Germany: Karlsruhe Institute of Technology, May 25-27.

Blaschke T., (2005), "Towards a framework for change detection based on image Objects", *Göttinger Geographische Abhandlungen*, 113, 1-9.

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

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(3-4), 239-258.

Bezdek J.C., (1981), "Pattern Recognition with Fuzzy Objective Function Algorithms", Kluwer Academic Publishers, Norwell, MA.

Bouziani M., Goita K., He D.-C., (2010), "Automatic change detection of buildings in urban environment from very high spatial resolution images using existing geodatabase and prior knowledge", *ISPRS Journal of Photogrammetry and Remote Sensing*, 65, 143-153.

Bovolo F., Bruzzone L., Marconcini M., (2008), "A novel approach to unsupervised change detection based on a semisupervised SVM and a similarity measure", *IEEE Transactions on Geoscience and Remote Sensing*, 46, 2070-2082.

Caridade C.M.R., Marçal A.R.S., Mendonça T., (2008), "The use of texture for image classification of black & white air photographs", *International Journal of Remote Sensing*, 29, 593-607.

Carleer A.P., Debeir Q., Wolff E., (2005), "Assessment of Very High Spatial Resolution Satellite Image Segmentations", *Photogrammetric Engineering and Remote Sensing*, 71, 1285-1294.

Chen Z., Elvidge C.D., Groeneveld D.P., (1999), "Vegetation change detection using

high spectral resolution vegetation indices”, In: Lunetta, R.S., Elvidge, C.D. (Eds.), *Remote Sensing Change Detection: Environmental Monitoring Methods and Applications*, Taylor & Francis, London, pp. 181–190.

Chen G., Hay G.J., Carvalho L.M.T., Wulder M.A., (2012a), “Object-based change Detection”, *International Journal of Remote Sensing*, 33, 4434–4457.

Clinton N., Holt A., Scarborough J., Yan L., Gong P., (2010), “Accuracy assesment measures for object-based image segmentation goodness”, *Photogrammetric Engineering and Remote Sensing*, 76 (3), 289-299.

Collins J.B., Woodcock C.E., (1996), “An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data”, *Remote Sensing of Environment*, 56, 66–77.

Cömert 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.

Cömert R., Matcı D.K., Emir H., Avdan U., (2017), “Nesne Tabanlı Sınıflandırma ile Yanmış Orman Alanlarının Tespiti”, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği IX. Sempozyumu (TUFUAB2017)*, 27-29 Nisan, Afyon.

Çölkesen İ., (2015), “Yüksek Çözünürlüklü Uydu Görüntüleri Kullanarak Benzer Spektral Özelliklere Sahip Doğal Nesnelerin Ayırt Edilmesine Yönelik Bir Metodoloji Geliştirme”, *Doktora Tezi, İstanbul Teknik Üniversitesi*.

Dai X.L., Khorram S., (1999), “Remotely sensed change detection based on artificial neural networks”, *Photogrammetric Engineering & Remote Sensing*, 65, 1187–1194.

Das T., (2009), “Land Use / Land Cover Change Detection: An Object Oriented Approach, Münster, Germany”, *Master’s Thesis, University of Münster*.

Definiens 2012. *Definiens Developer XD 2.0.4. Reference Book*. Munich, Germany: Definiens AG.

Delen, A., Şanlı F.B., (2017), “Nesne-Tabanlı Sınıflandırma Yöntemi ile Tarımsal Ürün Deseninin Belirlenmesi”, *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği IX. Sempozyumu (TUFUAB2017)*, 27-29 Nisan, Afyon.

Dey V., Zhang Y., Zhong M., (2010), “A Review on Image Segmentation Techniques with Remote Sensing Perspective”, *ISPRS TC VII Symposium*, 38, 31-42.

Dewen A.M., Yamagucji Y., (2009), “Land use and land cover change in Greater Dhaka, Bangladesh: Using remote sensing to promote sustainable urbanization”, *Applied Geography*, 29, 390–401.

Fung T., E. Ledrew., (1988), “The determination of optimal threshold levels for change detection using various accuracy indices”, *Photogrammetric Engineering and Remote Sensing*, 54 (1988), 1449–1454.

Gao J., (2009), "Digital Analysis of Remotely Sensed Imagery", McGraw-Hill, New York.

Gomez D.D., C. Butakoff, Ersboll B., Carstensen J.M., (2007), "Automatic change detection and quantification of dermatological diseases with an application to psoriasis images", *Pattern Recognition Letters*, 28 (9), 1012-1018.

Gopal S., Woodcock C., (1996), "Remote sensing of forest change using artificial neural networks", *IEEE Transactions on Geoscience and Remote Sensing*, 34, 398–404.

Griffiths P., Hostert P., Gruebner O., der Linden S.v., (2010), "Mapping megacity growth with multi-sensor data", *Remote Sensing of Environment*, 114, 426–439.

Hall O., Hay G.J., (2003), "A multiscale object-specific approach to digital change detection", *International Journal of Applied Earth Observation and Geoinformation*, 311-327.

Han J., Kamber M., Pei J., (2011), "Data Mining: Concepts and Techniques", Morgan Kaufmann, Amsterdam.

Haralick R.M., Shanmugam K., Dinstein I.H., (1973), "Textural Features for Image Classification", *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3, 610–621.

Haris K., Efstratiadis S.N., Maglaveras N., Katsaggelos A.K., (1998), "Hybrid image segmentation using watersheds and fast region merging", *IEEE Transactions on Image Processing*, 7 (12), 1684- 1699.

Holland D.A., Boyd D.S., Marshall P., (2006), "Updating topographic mapping in Great Britain using imagery from high-resolution satellite sensors", *ISPRS Journal of Photogrammetry and Remote Sensing*, 60, 212-223.

Hölbling D., Füreder P., Antolini F., Cigna F., Casagli N., Lang S., (2012), "A-Semi Automated Object-Based Approach for Landslide Detection Validated by Persistent Scatterer Interferometry Measures and Landslide Inventories", *Remote Sensing*, 4(5), 1310-1336.

Huang C., Song K., Kim S., Townshend J.R.G., Davis P., Masek J.G., Goward S.N., (2008), "Use of a dark object concept and support vector machines to automate forest cover change analysis", *Remote Sensing of Environment*, 112, 970–985.

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

Im J., Jensen J.R., (2005), "A change detection model based on neighborhood correlation image analysis and decision tree classification", *Remote Sensing of Environment*, 99, 326–340.

İrfanoğlu F., Balçık F.B., (2018), “Arazi Örtüsü Ve Arazi Kullanımı Sınıflarının Sentinel-2 Görüntüsü ve Nesne Tabanlı Sınıflandırma Yöntemiyle Belirlenmesi”, VII. Uzaktan Algılama-Cbs Sempozyumu, Eskişehir, 18-21 Eylül 2018.

Jensen J.R., (2005), “Introductory Digital Image Processing: A Remote Sensing Perspective”, Prentice Hall, Toronto.

Jensen L., Gorte B., (2001), “Principle of remote sensing, Chapter 12 Digital image classification”, ITC, Enchede. The Netherlands.

Jianyaa G., Haiganga S., Guoruia M., Qimingb Z., (2008). “A Review of Multi-Temporal Remote Sensing Data Change Detection Algorithms”, ISPRS Congress, 757–762, Beijing, China, 2008.

Jovanovic D., Govedarica M., Sabo F., Bugarinovic Z., Novovic O., Beker T., Lauter M., (2015). “Land Cover Change Detection by Using Remote Sensing – A Case Study of Zlatibor (Serbia)”, Geographica Pannonica, 19, 162-173.

Kauth R.J., Thomas G.S., (1976), “The Tasselled Cap – A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT”, LARS Symposia, 4B, 41–51.

Kalnay E., Cai M., (2003), “Impact of urbanization and land-use change on climate”. Nature, 423, 528–531.

Karlı F., Fidan M.H., Dihkan M., (2010), “Kızılötesi Hava Fotoğraflarından Bina Detayı Otomatik Olarak Çıkarımı”, III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Gebze – KOCAELİ, 11 – 13 Ekim 2010.

Kaur D., Kaur Y., (2014), “Various Image Segmentation Techniques: A Review”, International Journal of Computer Science and Mobile Computing, 3, 809-814.

Kavzoğlu T., (2001), “An Investigation of The Design And Use Of Feed-Forward Artificial Neural Networks In The Classification Of Remotely Sensed Images”, Doktora Tezi, Nottingham University.

Larose D.T., (2005), “Discovering Knowledge in Data: An Introduction to Data Mining”, John Wiley & Sons, New Jersey.

Lefebvre A., Corpetti T., Hubert-Moy L., (2008), “Object-oriented approach and texture analysis for change detection in very high resolution images”, In: Geoscience and Remote Sensing Symposium, IEEE International, 663-666.

Lillesand T.M., Kiefer R.W., Chipman J.W., (2008), “Remote Sensing and Image Interpretation”, sixth ed. John Wiley & Sons, Hoboken, NJ.

Listner C., Niemeyer I. (2011), Object-based change detection, Photogrammetrie - Fernerkundung - Geoinformation, 2011(4), 233–245.

Lizarazo I., Joana B., (2010), “Fuzzy image segmentation for urban land-cover classification”, *Photogrammetric Engineering and Remote Sensing*, 76 (2), 151-162.

Lu D., Mausel P., Brondizio E., Moran E. (2004). “Change detection techniques”, *International Journal of Remote Sensing*, 25(12), 2365–2401.

Lunetta R.S., (1999), “Applications, project formulation, and analytical approach. In: Lunetta, R.S., Elvidge, C.D. (Eds.), *Remote Sensing Change Detection: Environmental Monitoring Methods and Applications*. Taylor & Francis, London, pp. 1–19.

Machala M., Zejdova L., (2014), “Forest Mapping Through Object-Based Image Analysis of Multispectral and LIDAR Aerial Data”, *European Journal of Remote Sensing*, 47(1), 117-131.

Marangoz A.M., Karakış S., Oruç M., Büyüksalih G., (2005), “Nesne Tabanlı Görüntü Analizi ve İkonos Pan-Sharpned Görüntüsünü Kullanarak Yol ve Binaların Çıkarımı”, TMMOB Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı 28 Mart – 1 Nisan 2005, Ankara.

Marangoz A.M., Görmüş K.S., Oruç M., Kutoğlu Ş.H., Alkış Z., (2013), “Sakarya’nın Karasu İlçesindeki Kıyı Şeridinin Landsat Görüntülerinin Nesne Tabanlı Sınıflandırma Teknikleri Kullanılarak Zamansal Analizi”, TMMOB Harita ve Kadastro Mühendisleri Odası 14. Türkiye Harita Bilimsel ve Teknik Kurultayı 14-17 Mayıs 2013, Ankara.

Makkeasorn A., Chang N.-B., Li J., (2009), “Seasonal change detection of riparian zones with remote sensing images and genetic programming in a semi-arid watershed”, *Journal of Environmental Management*, 90, 1069–1080.

Malila W.A., (1980), “Change vector analysis: an approach for detecting forest changes with Landsat”, In: 6th Annual Symposium on Machine Processing of Remotely Sensed Data, 326–335, Purdue University, West Lafayette, Indiana.

McDermid G.J., Linke J., Pape A.D., Laskin D.N., McLane A.J., Franklin S.E., (2008), “Object-based approaches to change analysis and thematic map update: challenges and limitations”, *Canadian Journal of Remote Sensing*, 34, 462–466.

Mantero P., Moser G., Serpico S.B., (2005), “Partially supervised classification of remote sensing images through SVM-based probability density estimation”, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 559–570.

Metternicht G., (1999), “Change detection assessment using fuzzy sets and remotely sensed data: an application of topographic map revision”, *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, 221–233.

Melgani F., Bruzzone L., (2004), “Classification of hyperspectral remote sensing images with support vector machines”, *IEEE Transactions on Geoscience and Remote Sensing*, 42, 1778–1790.

Miller O., Pikaz A., Averbuch A., (2005), "Objects based change detection in a pair of gray-level images", *Pattern Recognition*, 38, 1976–1992.

Niemeyer I., Nori W., Elsidding E.N., (2008), "Detection of land cover changes using multi-temporal satellite imagery", *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, 947- 952.

Navulur K., (2007), "Multispectral Image Analysis Using the Object-Oriented Paradigm", Boca Raton, USA: CRC Press.

Pal M., (2005), "Random forest classifier for remote sensing classification", *International Journal of Remote Sensing*, 26, 217–222.

Polat N., Kaya Y., (2021), "Çok Bantlı Uydu Görüntüleriyle Orman Yangınlarında Hasar Tespiti", *Bartın Orman Fakültesi Dergisi* 23(1), 172-181.

Richards J.A., (2005), "Analysis of remotely sensed data: the formative decades and the future", *IEEE Transactions on Geoscience and Remote Sensing*, 43, 422–432.

Rignot E.J.M., van Zyl J.J., (1993), "Change detection techniques for ERS-1 SAR data", *IEEE Transactions on Geoscience and Remote Sensing*, 31, 896–906.

Sabuncu A., Sunar F., (2017), "Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: Van-Erciş Depremi Örneği", *Doğal Afetler ve Çevre Dergisi*, 3(1), 1-8.

Sabins F., (1997), "Remote Sensing: Principles and Interpretation", 3rd Ed. New York, Freeman.

Sali E., Wolfson H., (1992), "Texture classification in aerial photographs and satellite Data", *International Journal of Remote Sensing*, 13, 3395–3408.

Sandman H., Lertzmann K., (2003), "Combining high-resolution aerial photography with gradient-directed transects to guide field sampling and forest mapping in mountainous terrain", *Forest Science*, 49(3), 4290-443

Serra P., Pons X., Saurí D., (2003), "Post-classification change detection with data from different sensors: some accuracy considerations", *International Journal of Remote Sensing*, 24, 3311–3340.

Sesnie S.E., Gessler P.E., Finegan B., Thessler S., (2008), "Integrating Landsat TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments", *Remote Sensing of Environment*, 112, 2145–2159.

Shaban M.A., Dikshit O., (2001), "Improvement of classification in urban areas by the use of textural features: The case study of Lucknow city, Uttar Pradesh", *International Journal of Remote Sensing*, 22(4), 565-593.

Shankar B.U., (2007), “Novel Classification and Segmentation Techniques with Application to Remotely Sensed Image”, Lecture Notes on Computer Science Series 4400 Transactions on Rough Sets VII, Pages 295-380.

Singh A., (1989), “Review Article: Digital change detection techniques using remotely-sensed data”, International Journal of Remote Sensing, 10(6), 989–1003.

Smet P.D., Luis R.V.P.M. P., (2000), “Implementation and Analysis of an Optimized Rainfalling Watershed Algorithm”, Proceedings of SPIE, 3974, 759-766.

Smith A., (2010), “Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm” Journal of Spatial Science, 55, 69–79.

Stow D., (2010), “Geographic object-based image change analysis”, Handbook of Applied Spatial Analysis, Springer, Berlin Heidelberg, 565-582.

Şahin K., (2013), “Automatic Multi-Scale Segmentation of High Spatial Resolution Satellite Images Using Watersheds”, Yüksek Lisans Tezi, Ortadoğu Teknik Üniversitesi.

Tarhan Ç., (2007), “Detection of Environmental And Urban Change Using Remote Sensing And GIS”, Doktora Tezi, İzmir Yüksek Teknoloji Enstitüsü.

Tassi A., Gigante D., Modica G., Martino L.D., Vizzari M., (2021), “Pixel- vs. Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest: The Case Study of Maiella National Park”, Remote Sensing, 13(12), 2299.

Tavus B., Karataş K., Türker M., (2019), “Tarımsal alanlarda yüksek çözünürlüklü IKONOS uydu görüntüsünden nesne-tabanlı ürün deseni tespiti”, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi 25(5), 603-614.

Tonbul H., (2021) “Nesne-tabanlı sınıflandırmada doğal arazi örtüsü sınırlarını esas alan bölge tabanlı bölütleme (segmentasyon) algoritmasının optimizasyonu”, Doktora Tezi, Gebze Teknik Üniversitesi.

Torunlar H., Tuğaçı M.G., Duyan K., (2021), “Nesne Tabanlı Sınıflandırma Yönteminde Sentinel-2A Uydu Görüntüleri Kullanılarak Tarımsal Ürün Desenlerinin Belirlenmesi; Konya- Karapınar Örneği”, Türkiye Uzaktan Algılama Dergisi 3(2), 36-46.

Vapnik V.N., (2000), “The Nature of Statistical Learning Theory”, second ed. Springer, New York.

Versluis A., Rogan J., (2009), “Mapping land-cover change in a Haitian watershed using a combined spectral mixture analysis and classification tree procedure”, Geocarto International, 25, 85–103.

Wulder M.A., Ortellepp S.M., White J.C., Coops N.C., (2008a), “Impact of sunsurface-sensor geometry upon multi-temporal high spatial resolution satellite imagery”, Canadian Journal of Remote Sensing, 34, 455-461.

Yang C., DeMenthon D., Davis L.S., Duraiswami R., (2003), “Mean-shift analysis using quasi-Newton methods”, International Conference on Image Processing 2, 447-450.

Yang Q., Li X., Shi X., (2008), “Cellular automata for simulating land use changes based on support vector machines”, Computers & Geosciences, 34, 592–602.

Yılmaz M., (2018), “Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması ile Nesne-Tabanlı Sınıflandırması” Yüksek Lisans Tezi, Hacettepe Üniversitesi.

Yiğit A.Y., Uysal M., (2019), “Nesne Tabanlı Sınıflandırma ile Taşkın Alanlarının Analizi”, Dirençlilik Dergisi 3, 369-385.

Yiğit A.Y., Kaya Y., (2020), “Sentinel-2A uydu verileri kullanılarak sel alanlarının incelenmesi: Düzce örneği”, Türkiye Uzaktan Algılama Dergisi (TUZAL) 2(1), 01-09.

Yuan F., Sawaya K.E., Loeffelholz B.C., Bauer M.E., (2005), “Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing”, Remote Sensing of Environment 98, 317–328.

Zhang Y.J., (2001), “An Overview of Image and Video Segmentation in the last 40 years”, Proceedings of the 6th International Symposium on Signal Processing and Its Applications, 144-151.

ÖZGEÇMİŞ

Ayşe ÇELİK, 2009 yılında Gümüşhane Üniversitesi'nde lisans eğitimine Jeodezi ve Fotogrametri bölümünde başladığı üniversite eğitimini 2013 yılında bitirdi. Özel sektörde iş deneyimi edindi. 2018 yılında yüksek lisans eğitimini Gebze Teknik Üniversitesi Harita Mühendisliği Bölümünde eğitime başladı. Yüksek lisans eğitimini sürdürmekle birlikte 2018 yılında atandığı Gümüşhane Üniversitesi Kelkit Aydın Doğan Meslek Yüksekokulu'nda Tapu ve Kadastro Programında öğretim görevlisi görevine devam etmektedir.



EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Çelik A. ve Çölkesen İ., (2022) “Nesne Tabanlı Arazi Örtüsü Ve Arazi Kullanımı Değişimi Tespiti Analizi: Konya Yunak Örneği”, 4. International Palandoken Scientific Studies Congress, 541-549, Erzurum, Türkiye, 28-29 Nisan.

