



**HAVZA YÖNETİMİNDE COĞRAFİ BİLGİ
TEKNOLOJİLERİNİN KULLANIMI: PORSUK
HAVZASI DEĞİŞİM ANALİZİ ÖRNEKLEMİ**

Doktora Tezi

Milad DEGHANIJABBARLOU

Eskişehir 2024

**HAVZA YÖNETİMİNDE COĞRAFI BİLGİ TEKNOLOJİLERİNİN
KULLANIMI: PORSUK HAVZASI DEĞİŞİM ANALİZİ ÖRNEKLEMİ**

Milad DEGHANIJABBARLOU

Doktora Tezi

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Prof. Dr. Alper ÇABUK

(İkinci Danışman: Prof. Dr. Recep BAKIŞ)

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Nisan 2024

JÜRİ VE ENSTİTÜ ONAYI

Milad DEGHANIJABBARLOU'nun HAVZA YÖNETİMİNDE COĞRAFİ BİLGİ TEKNOLOJİLERİNİN KULLANIMI: PORSUK HAVZASI DEĞİŞİM ANALİZİ ÖRNEKLEMİ başlıklı çalışması 25/04/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof. Dr. Alper ÇABUK

Üye

: Prof. Dr. Murat ÖZYAVUZ

Üye

: Prof. Dr. Hakan Ahmet
NEFESLİOĞLU

Üye

: Prof. Dr. Mehmet ÇETİN

Üye

: Doç. Dr. Muammer TÜN

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

25/04/2024

DANIřMAN ONAYI

Daniřmanlıęını yrttęm Doktora ęrencisi Milad DEGHANIJABBARLOU, HAVZA YNETİMİNDE COęRAFİ BİLGİ TEKNOLOJİLERİNİN KULLANIMI: PORSUK HAVZASI DEęİřİM ANALİZİ RNEKLEMİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduęu tez tarafımca incelenmiř ve ęrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. Alper ABUK

ÖZET

HAVZA YÖNETİMİNDE COĞRAFI BİLGİ TEKNOLOJİLERİNİN KULLANIMI: PORSUK HAVZASI DEĞİŞİM ANALİZİ ÖRNEKLEMİ

Milad DEHGHANIJABBARLOU

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Nisan 2024

Danışman: Prof. Dr. Alper ÇABUK

(İkinci Danışman: Prof. Dr. Recep BAKIŞ)

Doğal havza yönetimi sürdürülebilir doğal kaynak kullanımını desteklemek için kritik bir stratejidir. Bu çalışmada, Porsuk Havzası'ndaki Arazi Kullanımı ve Arazi Örtüsü (LULC) değişikliği araştırması, 2000 yılından 2020 yılına kadar Landsat uydu görüntülerinin Google Earth Engine (GEE) platformunda kullanılmasıyla gerçekleştirilmiştir. Porsuk Havzası'ndaki değişim analizi için sırasıyla 2020, 2009 ve 2000 yıllarında Landsat-8, Landsat-5 ve Landsat-7 görüntüleri kullanılmıştır. Bu amaç doğrultusunda, Sınıflandırma ve Regresyon Ağaçları (CART), Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Gradyanla Güçlendirilmiş Ağaçlar (GBT) olmak üzere dört makine öğrenme algoritması kullanılmıştır. Bu çalışmanın temel amacı, dört farklı makine öğrenme modelinin performansını karşılaştırmaktır. Ayrıca, Landsat uydusunun termal bantları ve spektral indekslerin kullanımının sınıflandırmaya etkisini araştırmak amacıyla, iki farklı veri seti kullanılmış ve kullanılan yöntemler arasında, en iyi sonuçlar Rastgele Orman yöntemiyle elde edilmiştir. İlk veri seti için, Rastgele Orman algoritmasıyla elde edilen genel doğruluk değerleri 2000, 2009 ve 2020 yılları için sırasıyla %85, %89,38 ve %87,5 olarak elde edilmiştir. Sınıflandırma sonuçlarını iyileştirmek amacıyla ilk veri setine Landsat'ın termal bantları, NDVI, NDBI, NBI ve NDWI eklenmiştir. İkinci veri seti için, Rastgele Orman algoritmasıyla elde edilen genel doğruluk değerleri 2000, 2009 ve 2020 yılları için sırasıyla %89,35, %91,88 ve %90,62 olarak elde edilmiştir. Porsuk Havzası sekiz farklı sınıfa ayrılmıştır: ormanlar, seyrek ormanlar, yapay yüzeyler, su alanları, toprak, meralar, yaş ve kuru tarım alanları. 2000 ile 2020 yılları arasında Porsuk Havzası'ndaki yerleşim alanlarının 101,02 kilometrekarelik ve orman alanlarının 1003,19 kilometrekarelik bir artış gösterdiği belirlenmiştir.

Anahtar Sözcükler: Değişim analizi, Google earth engine, Landsat, Porsuk havzası, Makine öğrenimi.

ABSTRACT

THE USE OF GEOGRAPHIC INFORMATION TECHNOLOGIES IN WATERSHED MANAGEMENT: PORSUK BASIN CHANGE ANALYSIS EXAMPLE

Milad DEHGHANIJABBARLOU

Department of Remote Sensing and Geographic Information Systems

Eskişehir Technical University, Institute of Graduate Programs, April 2024

Supervisor: Prof. Dr. Alper ÇABUK

(Co-Supervisor: Prof. Dr. Recep BAKIŞ)

Natural watershed management is a critical strategy to support sustainable use of natural resources. In this study, Land Use and Land Cover (LULC) change research in the Porsuk Basin was conducted using Landsat satellite images on the Google Earth Engine (GEE) platform from 2000 to 2020. For change analysis in the Porsuk Basin, Landsat-8, Landsat-5, and Landsat-7 images were used in 2020, 2009, and 2000, respectively. For this purpose, four machine learning algorithms were used: Classification and Regression Trees (CART), Random Forest (RF), Support Vector Machine (SVM), and Gradient Boosted Trees (GBT). The main purpose of this study is to compare the performance of four different machine learning models. Additionally, to investigate the impact of using Landsat satellite's thermal bands and spectral indices on classification, two different datasets were employed, and among the methods utilized, the best results were achieved with the Random Forest method. For the first data set, the overall accuracy values obtained with the Random Forest algorithm were 85%, 89.38%, and 87.5% for the years 2000, 2009, and 2020, respectively. Landsat's thermal bands, NDVI, NDBI, NBI, and NDWI were added to the initial data set to enhance the classification results. For the second data set, the overall accuracy values obtained with the Random Forest algorithm were 89.35%, 91.88%, and 90.62% for the years 2000, 2009, and 2020, respectively. Porsuk Basin is divided into eight different classes: forests, sparse forests, artificial surfaces, water areas, soil, pastures, wet agricultural areas, and dry agricultural areas. It was determined that between 2000 and 2020, the residential areas in the Porsuk Basin increased by 101.02 square kilometers and the forest areas increased by 1003.19 square kilometers.

Keywords: Change analysis, Google earth engine, Landsat, Porsuk basin, Machine learning.

TEŞEKKÜR

Yıllar boyunca ciddi bir emek ve özveri ile hazırladığım doktora tezimi tamamlamanın heyecanını ve gururunu yaşıyorum. Bu bölümü bana yardımlarını esirgememiş ve beni teşvik etmiş insanlara teşekkür etmek için bir fırsat olarak kullanacağım. Öncelikle danışmanlığımı üstlenen, konu seçiminden araştırmanın yürütülmesine dek beni sınırlamayıp özgür bırakan, doktora öğrencisinin yeterliğini göstermesine olanak tanıyan hocam Prof. Dr. Alper ÇABUĞ'a danışmanlığı için çok teşekkür ediyorum. Sonrasında, ailemden beni bu yolda desteklediği için çok teşekkür ediyorum.

Milad DEGHANIJABBARLOU

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Milad DEGHANIJABBARLOU

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER.....	VIII
TABLolar DİZİNİ.....	XI
ŞEKİLLER DİZİNİ.....	XII
SİMGELER VE KISALTMALAR DİZİNİ.....	XV
1. GİRİŞ	1
1.1. Amaç.....	4
1.2. Kapsam	4
1.3. Araştırma Soruları.....	4
1.4. Hipotezler.....	5
1.5. Sınırlılıklar.....	6
1.6. Temel Tanımlar	6
1.6.1. Havza	6
1.6.2. Havza yönetimi	7
1.6.3. Coğrafi Bilgi Sistemi (CBS)	7
1.6.4. Uzaktan algılama	8
1.6.5. Havza yönetiminde uzaktan algılama uygulaması	10
1.6.6. Arazi kullanım değişikliği.....	13
1.6.7. Arazi kullanım planlaması	13
1.6.8. Değişim analizi.....	14
1.6.9. Görüntü sınıflandırması	14

2. LİTERATÜR ÖZETİ.....	15
3. MATERYAL VE YÖNTEM.....	23
3.1. Materyal.....	23
3.1.1. Çalışma alanı.....	23
3.1.2. Kullanılan veriler ve yazılımlar	24
3.1.2.1. Landsat uydusu.....	24
3.1.2.2. Spektral indeksler	28
3.1.2.3. İndeksler arasındaki korelasyon	30
3.1.2.4. Google Earth Engine	32
3.2. Yöntem	33
3.2.1. Değişim analizi teknikleri	33
3.2.1.1. Cebirsel yöntemler	33
3.2.1.2. Dönüşüme dayalı yöntemler.....	35
3.2.1.3. Sınıflandırmaya dayalı yöntemler.....	37
3.2.2. Çalışmada kullanılan değişim analizi teknikleri	38
3.2.2.1. Destek Vektör Makinesi (SVM).....	38
3.2.2.2. Sınıflandırma ve Regresyon Ağaçları (CART).....	39
3.2.2.3. Rastgele Orman (Random Forest)	41
3.2.2.4. Gradyanla Güçlendirilmiş Ağaçlar (Gradient Boosted Trees)	42
3.2.3. Yapılan çalışmalar.....	44
3.2.3.1. Çalışmada kullanılan uydu görüntülerini seçmek	45
3.2.3.2. Medyan yöntemiyle görüntülerin mozaïği	48
3.2.3.3. Test ve eğitim örneklerini belirtmek.....	49
3.2.3.4. Seçtiğimiz dört algoritma ile sınıflandırma	50
3.2.3.5. Sınıflandırma sonuçlarının doğruluk değerlendirmesi	52
3.2.3.6. Sınıflara ait alan hesaplanması	52
3.2.3.7. En iyi yöntem ile değişim analizi yapmak.....	53
4. ARAŞTIRMA BULGULARI VE SONUÇLARI	54
4.1. Araştırma Bulguları.....	54
4.1.1. Çalışma alanı.....	54
4.1.1.1. Sayısal yükseklik modeli.....	54
4.1.1.2. Akarsular haritası.....	55

4.1.1.3. Eğim haritası.....	55
4.1.1.4. Akış yönü haritası.....	56
4.1.1.5. Bakı haritası.....	57
4.1.2. Sınıflandırma	58
4.1.2.1. Rastgele Orman	58
4.1.2.2. Support Vektor Makinesi (SVM).....	65
4.1.2.3. Gradyanla Güçlendirilmiş Ağaçlar.....	71
4.1.2.4. Sınıflandırma ve Regresyon Ağaçları (Cart).....	77
4.2. Araştırma Sonuçları.....	83
4.2.1. Sınıflandırma sonuçlarının doğruluk değerlendirmesi.....	83
4.2.1.1. Genel doğruluk	83
4.2.1.2. Kappa katsayısı	84
4.2.1.3. Hata matrisi	85
4.2.2. Değişim analizi.....	97
4.2.2.1. Rastgele Orman	98
4.2.2.2. Gradyanla Güçlendirilmiş Ağaçlar.....	100
4.2.2.3. Değişim analizin sonucu	102
4.2.3. Sonuçlar.....	104
5. TARTIŞMA VE ÖNERİLER.....	106
KAYNAKÇA.....	110
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 3.1. Landsat uydularının sensörleri ve fırlatma tarihleri.....	24
Tablo 3.2. Landsat 4-5 TM algılayıcı bantları ve özellikleri	25
Tablo 3.3. Landsat 7 ETM+ algılayıcı bantları ve özellikleri	25
Tablo 3.4. Landsat 8 OLI algılayıcı bantları ve özellikleri	26
Tablo 3.5. İndekslerin formülleri	29
Tablo 3.6. Spektral indekslerin istatistiksel parametreleri	30
Tablo 3.7. SVM yönteminin parametreleri	39
Tablo 3.8. CART yönteminin parametreleri	40
Tablo 3.9. Rastgele Orman yönteminin parametreleri	42
Tablo 3.10. Gradyanla Güçlendirilmiş Ağaçlar yönteminin parametreleri.....	43
Tablo 4.1. Genel doğruluk değeri sınıflandırma yöntemlerine göre (veri seti 1 ve 2)	84
Tablo 4.2. Kappa katsayısının değeri sınıflandırma yöntemlerine göre (veri seti 1 ve 2)	85
Tablo 4.3. 2000 tarihli Rastgele Orman yönteminin hata matrisi	86
Tablo 4.4. 2000 tarihli SVM yönteminin hata matrisi	87
Tablo 4.5. 2000 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi.....	88
Tablo 4.6. 2000 tarihli CART yönteminin hata matrisi	89
Tablo 4.7. 2009 tarihli Rastgele Orman yönteminin hata matrisi	90
Tablo 4.8. 2009 tarihli SVM yönteminin hata matrisi	91
Tablo 4.9. 2009 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi.....	92
Tablo 4.10. 2009 tarihli CART yönteminin hata matrisi	93
Tablo 4.11. 2020 tarihli Rastgele Orman yönteminin hata matrisi	94
Tablo 4.12. 2020 tarihli SVM yönteminin hata matrisi	95
Tablo 4.13. 2020 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi.....	96
Tablo 4.14. 2020 tarihli CART yönteminin hata matrisi	97
Tablo 4.15. Rastgele Orman algoritması ile her yıl ve sınıf için hesaplanan alanlar.....	98
Tablo 4.16. Gradyanla güçlendirilmiş ağaçlar algoritması ile her yıl ve sınıf için hesaplanan alanlar	100
Tablo 4.17. Değişim analizin sonucu (km ²)	102
Tablo 4.18. Değişim analizin sonucu (%)	102

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Coğrafi bilgi sisteminin temel bileşenleri (Ershad & Ali, 2020)	8
Şekil 1.2. Uzaktan algılamanın genel süreci ve etkili unsurları (Ouattara et al., 2004)	9
Şekil 3.1. Porsuk Havzası'nın konumu	23
Şekil 3.2. 2000 yılına ait Landsat 7 uydu görüntüleri	27
Şekil 3.3. 2009 yılına ait Landsat 5 uydu görüntüleri	27
Şekil 3.4. 2020 yılına ait Landsat 8 uydu görüntüleri	28
Şekil 3.5. İndeksler arasındaki korelasyon	31
Şekil 3.6. Google Earth Engin platformu	33
Şekil 3.7. Porsuk Havzası'na ait değişim analizin akış şeması	44
Şekil 3.8. Ölçek faktörü uygulaması için yazılan kod	46
Şekil 3.9. Seçtiğimiz Landsat 8 uydusunun uygulanması için yazılan kodlar	46
Şekil 3.10. Seçtiğimiz Landsat 7 uydusunun uygulanması için yazılan kodlar	47
Şekil 3.11. Seçtiğimiz Landsat 5 uydusunun uygulanması için yazılan kodlar	47
Şekil 3.12. İndekslerin açıklanması için yazılan kodlar	48
Şekil 3.13. Görüntülerin mozaik ve klip için yazılan kodlar	49
Şekil 3.14. Eğitim örneklerinin belirlemesi için yazılan kodlar	50
Şekil 3.15. Test örneklerin belirlemesi için yazılan kodlar	50
Şekil 3.16. CART yöntemini uygulamak için yazılan kodlar	51
Şekil 3.17. SVM yöntemini uygulamak için yazılan kodlar	51
Şekil 3.18. Rastgele Orman yöntemini uygulamak için yazılan kodlar	51
Şekil 3.19. Gradyanla Güçlendirilmiş Ağaçlar yöntemini uygulamak için yazılan kodlar	52
Şekil 3.20. Eğitim örneklerinin doğruluk değerlendirmesi için yazılan kodlar	52
Şekil 3.21. Test örneklerinin doğruluk değerlendirmesi için yazılan kodlar	52
Şekil 3.22. Sınıflara ait alanın hesaplanması için yazılan kodlar	53
Şekil 4.1. Sayısal Yükseklik Modeli	54
Şekil 4.2. Akarsular haritası	55
Şekil 4.3. Eğim haritası	56

Şekil 4.4. Akış yönü haritası.....	57
Şekil 4.5. Bakı haritası.....	58
Şekil 4.6. Rastgele Orman yöntemiyle 2000 Tarihli sınıflandırılmış görüntü (veri seti 1).....	59
Şekil 4.7. Rastgele Orman yöntemiyle 2000 Tarihli sınıflandırılmış görüntü (veri seti 2).....	60
Şekil 4.8. Rastgele Orman yöntemiyle 2009 Tarihli sınıflandırılmış görüntü (veri seti 1).....	61
Şekil 4.9. Rastgele Orman yöntemiyle 2009 Tarihli sınıflandırılmış görüntü (veri seti 2).....	62
Şekil 4.10. Rastgele Orman yöntemiyle 2020 Tarihli sınıflandırılmış görüntü (veri seti 1).....	63
Şekil 4.11. Rastgele Orman yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2).....	64
Şekil 4.12. SVM yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)	65
Şekil 4.13. SVM yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)	66
Şekil 4.14. SVM yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)	67
Şekil 4.15. SVM yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)	68
Şekil 4.16. SVM yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)	69
Şekil 4.17. SVM yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)	70
Şekil 4.18. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)	71
Şekil 4.19. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)	72
Şekil 4.20. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)	73
Şekil 4.21. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)	74
Şekil 4.22. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)	75
Şekil 4.23. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)	76
Şekil 4.24. CART yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)	77

Şekil 4.25. CART yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)	78
Şekil 4.26. CART yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)	79
Şekil 4.27. CART yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)	80
Şekil 4.28. CART yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)	81
Şekil 4.29. CART yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)	82
Şekil 4.30. Rastgele Orman algoritması ile her sınıf için hesaplanan alanlar (km ²)	99
Şekil 4.31. Rastgele Orman algoritması ile her sınıf için hesaplanan alanlar (%)	99
Şekil 4.32. Gradyanla güçlendirilmiş ağaçlar algoritması ile her sınıf için hesaplanan alanlar (km ²)	101
Şekil 4.33. Gradyanla güçlendirilmiş ağaçlar algoritması ile her sınıf için hesaplanan alanlar (%)	101

SİMGELER VE KISALTMALAR DİZİNİ

CBS	: Coğrafi Bilgi Sistemleri
CVA	: Değişim Vektör Analizi
GS	: Gram-Schmidt Dönüşümü
PCA	: Temel Bileşen Analizi
TC	: Tasselled Cap
SVM	: Support Vektör Makinesi
GTB	: Gradyanla Güçlendirilmiş Ağaçlar
RF	: Rasgele Orman
CART	: Sınıflandırma ve Regresyon Ağaçları
NDVI	: Normalleştirilmiş Fark Bitki Örtüsü İndeksi
NDWI	: Normalleştirilmiş Fark Su İndeksi
NDBI	: Normalleştirilmiş Fark Yapı İndeksi
NBI	: Yeni Yerleşim İndeksi

1. GİRİŞ

Havza yönetimi kavramı, binlerce yıldır var olan bir olgudur. MÖ 800'e ait Atharva Veda metni, havza yönetimine ilişkin ilk yazılı referans olabilecek bir belge sunar. Atharva Veda ayet 19, 2.1 şöyle der: “Dağlardan, kuyulardan, nehirlerden gelen suyun ve ayrıca yağmur suyunun içme, tarım ve sanayide kullanılması ve muhafaza edilmesi için uygun yönetsel eylemde bulunulmalıdır” (Chandra, 1990).

Batı'da, Benjamin Franklin gibi erken tarihlerde, 1790 gibi, havza yönetimi ihtiyacı fark edilmiştir. Ancak, havza yönetimi bütüncül bir kavram olarak tanımlanmamıştır ve 20. yüzyılın ortalarına kadar net bir şekilde tanımlanmamıştır. Yirminci yüzyılın sonlarına gelindiğinde, birçok bölgedeki nüfus artışı, toprak, su ve diğer doğal kaynakların artan kısıtlamalarına yol açmıştır. Tatlı su kaynaklarının kıtlığı, tarım arazilerinin kirlenmesi ve kirletilmiş nehirler milyonlarca insanı etkilemiştir. Günümüzde dünyadaki ülkelerin neredeyse yarısı, düşük ila çok düşük tatlı su kaynaklarına sahiptir (Cai et al., 2003).

Havzalar bir ulusun sağlığını belirleyen doğal çevre ve arazi yönetim birimleridir. Havzalardaki zayıf ekosistem yönetimi, hassas ortamlarda ekosistemin çökmesine neden olabilecek şekilde havzanın işleyişinin bozulmasına neden olmuştur ve bununla sonuçlanacaktır (Eswaran & Samra, 1997).

Havza yönetimi, fiziksel su ve toprak kullanımı ve korunmasına odaklanmaktan, sosyal, ekonomik ve çevresel kalkınmanın entegrasyonuna doğru evrilmiştir. Bu değişikliklerin bir parçası olarak, geleneksel havza yönetimi, eğer toplumun ihtiyaçlarını karşılamak istiyorsa, geleneksel odağını yabani alanlardan uzaklaştırarak kentsel sınırları ve kentleşmiş alanları da içermelidir (Neary, 2000).

Havza yönetimi, büyük ölçüde bitki örtüsü ve arazi kullanım yönetiminin su kalitesi, erozyon ve çökelme üzerindeki etkilerini inceler. Bu çerçevede, arazi yönetimi kararlarının tek başına alınamayacağı farkındalığıyla birlikte, havza yönetimi ilkeleri birçok çevresel ve doğal kaynak yönetimi kararının temeli olarak hizmet etmektedir (Lin & Ueta, 2012; Karcher et al., 2013).

Yeryüzündeki bitki örtüsü, hem insanlara yiyecek ve yakıt sağlamakta hem de atmosferle su, enerji ve gaz alışverişini kontrol etmede önemli bir rol oynamaktadır. Ayrıca, bitki örtüsü biyokimyasal döngüler için bir kaynak işlevi görmektedir (Sellers et al., 1997).

İnsanoğlu, uzun bir süredir dünyadaki kaynakları kullanarak ihtiyaçlarını karşılamaktadır. Nüfus artışı ve yaşam standartlarının yükselmesiyle birlikte, bu kaynakların kullanımı kaçınılmaz olarak artmaktadır. Ancak, çevrenin mantıksızca sömürülmesi önemli bir sorundur. Büyük çevresel felaketlerin artmasıyla, özellikle de iklim değişikliği gibi sorunların boyutu ve karmaşıklığı gün geçtikçe artmaktadır (Minaei & Kainz, 2016).

Bir alandaki arazi kullanımı ve örtüsü modeli, sosyo-ekonomik ve doğal faktörlerin ve bu faktörlerin insanlar tarafından zaman ve mekanda kullanımının bir sonucudur. Tarihi boyunca, sel, fırtına ve deprem gibi doğal afetler nedeniyle arazi örtüsünde değişiklikler yaşanmıştır. Ancak, insanlar var olduklarından beri, hayatta kalmalarını sürdürmek için doğal çevreyi değiştirmişlerdir, bu da önceden belirlenmiş bir amaçla gerçekleşmiştir (Turner & Gardner, 2015).

Yapılan araştırmalara göre, dünyadaki arazi kullanım değişikliği ve arazi örtüsünün bozulmasına neden olan ana faktörler arasında aşırı otlatma, ormansızlaşma, tarımsal faaliyetler, aşırı kaynak sömürüsü ve sanayileşme bulunmaktadır (Ayoub et al., 1991).

Bu tür değişiklikler aynı zamanda radyatif dengeyi ve enerji akışını etkiler, biyokimyasal döngüyü değiştirir ve ekolojik kompozisyon ile dengeyi, biyoçeşitliliği, toprak verimliliğini, toprak kalitesini, akış ve sedimantasyon oranını etkiler. Bu tür çevresel değişikliklerin sonuçları başlangıçta fark edilmeyebilir, ancak zamanla yıkıcı hale gelebilir. Bu nedenle, arazi kullanımı insan etkisinin bir yansıması olduğundan, küresel çevresel değişimle ilgili artan endişelerin ortasında, arazi kullanımı sorunlarının önemi ve bu değişikliklerin potansiyel etkileri hakkındaki uyarılar zaman içinde artmıştır (Le-Xiang et al., 2006).

Arazi kullanım türleri ve insanoğlunun artan ihtiyaçlarını karşılamak için arazi kullanım planlarının seçimi, tasarımı ve uygulanmasındaki değişiklikler hakkında bilgi sahibi olmak önemlidir. Bu bilgi aynı zamanda nüfus arttıkça talepte meydana gelen değişikliklerin neden olduğu arazi kullanım değişikliğinin izlenmesine yardımcı olur ve küresel çevresel değişim çalışmalarında önemlidir. Coğrafi Bilgi Sistemleri (CBS) ve uzaktan algılama, arazi kullanımı değişikliklerini izlemek, analiz etmek ve anlamak için güçlü araçlar sağlar. Bu teknolojiler, geniş alanlardaki arazi kullanımı ve arazi örtüsü değişikliklerini algılamak için uzaktan algılama verilerini kullanır. Uydu görüntüleri, yeryüzündeki arazi örtüsünü detaylı bir şekilde gözlemlememizi sağlar (Lu et al., 2004).

Çalışmanın özgün yönleri veya bir başka deyişle çalışmanın havza yönetimi alanında yapılan diğer araştırmalardan farkı:

- Porsuk Havzası'nda arazi kullanımı sınıflandırılması ve değişim analizi: Bu çalışma, Porsuk Havzası'nda Coğrafi Bilgi Teknolojileri (CBS, uzaktan algılama vb.) kullanarak arazi kullanımı değişimini analiz etme amacını taşımaktadır. Bu havzada daha önce yapılan çalışmalarda değişim analizi yapılmamıştır.
- Düşük çözünürlüklü uydu görüntüleriyle çalışma: Çalışma, düşük çözünürlüklü uydu görüntülerinin kullanılabilirliğini ve bu görüntülerle yapılan arazi kullanımı sınıflandırmasının doğruluğunu araştırmaktadır.
- Kentsel alanların ayırt edilmesi: Porsuk Havzası'ndaki kentsel alanları diğer arazi kullanım sınıflarından ayırt etme zorluğuna odaklanan bir çalışmadır. Kentsel alanların doğru bir şekilde sınıflandırılması ve analiz edilmesi, kentsel planlama ve arazi yönetimi için önemlidir. Bu çalışma, kentsel alanları diğer sınıflardan ayırt etmek için potansiyel yöntemler ve teknikler sunmaktadır.
- Sınırlı veri erişimi ve kontrol nokta zorlukları: Çalışma, sınırlı veri erişimi ve kontrol nokta verilerinin elde edilmesi gibi pratik sorunları ele almaktadır. Bu zorluklar, gerçek dünya uygulamalarında sıkça karşılaşılan sorunlardır ve çalışma, bu zorluklarla başa çıkmak için alternatif yaklaşımlar sunmaktadır.

Bu doktora tezi, çalışmada alanında aşağıdaki boşlukları doldurmayı hedeflemektedir:

- Porsuk Havzası'nda yapılan arazi kullanım analizlerin yetersizliği: Porsuk Havzası'nda Coğrafi Bilgi Sistemlerinin (CBS) arazi kullanımı analizindeki etkinliği ve uygulama alanlarına yönelik sınırlı çalışmalar bulunmaktadır. Bu çalışma, Porsuk Havzası'nda arazi kullanım analizleri yaparak bu boşluğu doldurmaktadır.
- Düşük çözünürlüklü görüntülerin kentsel alanların sınıflandırılmasında zorlukları: Bu çalışma, düşük çözünürlüklü görüntülerin kentsel alanları doğru bir şekilde sınıflandırmak için potansiyel yöntemler ve teknikleri ele alarak bu boşluğu doldurmaktadır.
- Düşük çözünürlüklü görüntülerin kullanılabilirliği: Düşük çözünürlüklü uydu görüntülerinin arazi kullanımı analizinde kullanılabilirliği hakkında bilgiler sunulmaktadır. Bu çalışma, düşük çözünürlüklü görüntülerle yapılan arazi

kullanımı sınıflandırmasının doğruluğunu değerlendirerek bu boşluğu doldurmaktadır.

1.1. Amaç

Bu doktora tezinin amacı, Porsuk Havzası'nda coğrafi bilgi teknolojilerinin kullanımıyla arazi kullanımı değişikliklerini analiz etmek ve uygun bant bileşimi ve sınıflandırma yöntemini belirlemektir. Arazi kullanımını belirlemek için uygun bant bileşimini ve sınıflandırma yöntemini belirlemek, doğru sonuçların elde edilmesi için kritik öneme sahiptir. Bu çalışma, mevcut verilerin ve sınırlılıkların dikkate alınmasıyla gerçekleştirilmiş ve Porsuk Havzası'ndaki arazi kullanımı değişikliklerini anlamamıza yardımcı olmuştur.

Bu çalışma, Porsuk havzası'nı seçilmiş bir çalışma alanı olarak kullanılmaktadır. Porsuk Havzası, Türkiye'nin önemli su kaynaklarından biridir ve arazi kullanımı değişiklikleri bu havza üzerinde önemli etkilere sahiptir. Bu çalışmanın amacı, bu havzada gerçekleşen arazi kullanımı değişikliklerini analiz etmektir.

1.2. Kapsam

Bu çalışmada, Porsuk havzası çalışma alanı olarak seçilmiştir. Porsuk Havzası, Türkiye'nin batısında yer alan ve önemli bir tarım alanı olan bir havzadır. Bu doktora tezi, havzanın arazi kullanımı değişikliklerini analiz etmek için uydu görüntülerini kullanmış ve belirli bir zaman aralığında meydana gelen değişiklikleri incelemiştir.

Çalışmanın kapsamı ayrıca mevcut veriler ve sınırlılıklarla sınırlıdır. Çalışma, mevcut uydu görüntüleri ve diğer mevcut verileri kullanılarak gerçekleştirilmiştir. Veri toplama süreci, mevcut kaynaklarla sınırlıdır.

Ayrıca, alanın bazı bölgelerine sınırlı erişim olabileceğinden kontrol nokta verilerinin elde edilmesinin zorluğu dikkate alınmıştır. Kontrol nokta verileri, sınıflandırma yönteminin doğruluğunu değerlendirmek ve sonuçları doğrulamak için kullanılan önemli verilerdir. Ancak, çalışma alanının belirli bölgelerine erişimin kısıtlı olması ve bu sürecin yüksek maliyeti, kontrol noktalarının elde edilmesini zorlaştırmaktadır.

1.3. Araştırma Soruları

- Porsuk Havzası'ndaki arazi kullanımını analiz etmek için en uygun bant bileşimi ve sınıflandırma yöntemi hangisidir?

Bu soru, Porsuk Havzası'nda arazi kullanımını analiz etmek için kullanılacak uydu görüntülerinin en uygun bant bileşimini ve sınıflandırma yöntemini belirlemeyi

amaçlamaktadır. Çalışma alanında farklı bant kombinasyonları ve sınıflandırma yöntemleri kullanılarak elde edilen sonuçların karşılaştırılması ve doğruluğunun değerlendirilmesi hedeflenmektedir.

- Seçilen bant bileşimi ve sınıflandırma yöntemiyle Porsuk Havzası'ndaki arazi kullanımı değişikliği, 2020 yılında 2000 yılına göre nasıl değişmiştir?

Bu soru, belirlenen en uygun bant bileşimi ve sınıflandırma yöntemi kullanılarak Porsuk Havzası'ndaki arazi kullanımının değiştiğini incelemeyi amaçlamaktadır. Uydu görüntüleri ve diğer ilgili veriler kullanılarak elde edilen sonuçlar, farklı zaman dilimlerindeki arazi kullanımının değişimini göstermeye yönelik analizler içermektedir.

- Termal bant ve indekslerin kullanılması, sadece uydu görüntülerinden yapılan sınıflandırmaya kıyasla daha iyi bir sınıflandırma ve doğrulama sonucu sağlar mı?

Bu soru, termal bant ve indekslerin, sadece uydu görüntülerinden yapılan sınıflandırmaya kıyasla daha iyi bir sınıflandırma ve doğrulama sonucu elde edip edemediğini incelemeyi amaçlamaktadır. Bu çalışma, termal bant ve indekslerin arazi kullanımını daha hassas bir şekilde sınıflandırma ve doğrulama sürecine katkı sağlayıp sağlamadığını değerlendirmektedir.

- Porsuk Havzası'ndaki kentsel alanları diğer sınıflardan ayırt etme zorluğu nasıl aşılabılır?

Bu soru, Porsuk Havzası'ndaki kentsel alanların diğer arazi kullanım sınıflarından ayırt edilmesinde yaşanan zorlukları ele almaktadır. Uydu görüntülerinin düşük çözünürlüklü olması ve kentsel alanların karmaşık özelliklere sahip olması, doğru bir sınıflandırma için zorluklar yaratır. Bu çalışma, kentsel alanları diğer sınıflardan doğru bir şekilde ayırt etmek için potansiyel yöntemleri ve teknikleri incelemektedir.

- Çalışma alanının geniş olması ve farklı zamanlarda çekilmiş uydu görüntülerinin kullanılması zorluğu nasıl aşılabılır?

Bu soru, çalışma alanının geniş olması ve aynı tarihe ait uydu görüntülerin bulunmasının zorluğunun nasıl aşılanacağını ele almaktadır. Çalışma alanının genişliği, uydu görüntülerinin farklı zamanlarda çekilmesi veya farklı sensörlerden elde edilmesi gibi sorunlara yol açabilir.

1.4. Hipotezler

- Termal bant ve indeksler ile birlikte, sadece uydu görüntüleri kullanmaktan daha iyi bir sınıflandırma ve doğrulama sonucu elde edeceğiz.

Bu hipotez, termal bantlar ve çeşitli indekslerin eklenmesiyle birlikte uydu görüntülerinin kullanımının, sınıflandırma ve doğrulama sonuçları açısından daha iyi sonuçlar vereceğini öngörmektedir. Bu hipotez, uydu görüntülerinden elde edilen verilerin kalitesini artırarak, Porsuk Havzası'ndaki arazi kullanımının sınıflandırılmasında ve değişim analizinde daha hassas sonuçlar alınabileceğini öne sürmektedir.

- En iyi sınıflandırma yöntemi, çalışma alanın kriterlerine göre Rastgele Orman yöntemidir.

Bu hipotez, Porsuk Havzası'ndaki arazi kullanımının sınıflandırılması için kullanılan farklı yöntemler arasında Rastgele Orman yönteminin en iyi sonuçları vereceğini öngörmektedir.

Tez çalışması sürecinde, bu hipotezlerin geçerliliği ve doğruluğu araştırma verileri üzerinde analiz ve değerlendirme yaparak incelenmiştir.

1.5. Sınırlılıklar

Bu çalışmanın ayrıca sınırlılıkları dikkate alınmaktadır. Düşük çözünürlüklü uydu görüntüleri, çalışma alanının genişliği ve uydu görüntülerinin tarih uyumunun zorluğu gibi sınırlılıklar göz önünde bulundurmaktadır. Bu sınırlılıklar, veri toplama ve analiz sürecini etkileyebilir, ayrıca kontrol noktaların eksikliğide bu süreci zorlaştırabilir ancak mevcut veriler ve imkanlarla en iyi sonuçları elde etmek için çalışma yapılmıştır.

1.6. Temel Tanımlar

Temel tanımlar bölümü, tezin önemli bir parçasıdır ve çalışmanın amacının daha iyi anlaşılmasına yardımcı olur. Bu bölümde, tezin konusu ile ilgili anahtar terimlerin tanımları ve çalışmanın amacına yönelik olarak kullanılan diğer tanımlar yer almaktadır.

1.6.1. Havza

Bir akarsu tarafından parçalanan, kendine has doğal kaynakları bünyesinde barındıran, etrafı dağ ve tepelerle çevrili, suları aynı denize, ırmağa veya göle akan, belirli büyüklükteki arazi parçasıdır. Havzalar insanoğlu ve toplumlar için, temiz su ve su kaynaklarının regule edilmesi, toprak erozyonu, karbon depolama ve biyolojik kaynaklar gibi hayati öneme sahip temel mal ve hizmetler sağlayan kompleks sistemlerdir. Aynı zamanda havza, bir akarsu sistemi tarafından boşaltılan, topoğrafik olarak belirlenmiş bir alandır; bir akarsu veya nehir üzerinde o noktadan sonra akan bir noktanın üzerindeki toplam alandır. Havza hidrolojik bir tepki birimi, biyofiziksel bir birim ve içinden geçen malzeme, enerji ve bilgi açısından bütünsel bir ekosistemdir. Dolayısıyla fiziksel analizler

için yararlı bir birim olmasının yanı sıra, yönetim planlaması ve uygulaması için de uygun bir sosyoekonomik-politik birim olabilir. Havzaların boyutları binlerce kilometrekareden tatlı su tarafından kurutulan küçük bir alana kadar değişebilir (Ghafouri et al., 2012).

1.6.2. Havza yönetimi

Bir su toplama havzasında ekolojinin temel esasları dikkate alınarak, Toplumun sosyal, kültürel ve ekonomik kalkınmasını sağlayacak şekilde, doğal kaynakların sürdürülebilir kullanımının planlanması, geliştirilmesi ve yönetilmesidir (Perera, 2017). Havza yönetimi, su kaynakları yönetimi ve hidrolojik döngüye odaklanmaktan, bir havzanın sınırları içindeki bir peyzajdaki biyolojik, fiziksel ve sosyal unsurların yönetilmesine yönelik mevcut entegre yaklaşıma doğru gelişmiştir (Folliott ve ark. 2002). Havzaların yalnızca su kaynaklarının değil, aynı zamanda genel olarak ekosistemlerin yönetimi için de en iyi birimler olduğu fikri etrafında güçlü bir küresel fikir birliği ortaya çıkıyor (Montgomery et al., 1995).


Dünya Bankası, peyzaj iyileştirmeleri, verimlilik artışları ve doğal kaynakların gerçek sürdürülebilirliğine ulaşma arasındaki bağlantıları belirlemede, havza yönetimi değerlendirme yaklaşımlarını anahtar bir araç olarak kullanmaktadır. Havza yönetimine yönelik yaklaşımlar, sadece hidrolojik hususlara sınırlı kalmaz; aynı zamanda yukarı ve aşağı havza alanları arasındaki ilişkileri tanırlar ve toprağa ve suya zarar vermeden istenilen mal ve hizmetleri elde etmek için bir havza içindeki arazi ve kaynakların kullanımını amaçlar (Neary, 2000).

Havza yönetimi, bir havzada kullanılan arazi, su ve diğer doğal kaynakları organize etme ve yönlendirme sürecidir, bu süreçte toprak ve havza kaynakları üzerindeki etkiyi azaltırken uygun ürün ve hizmetleri sağlar. Bu yaklaşım, toprak, su ve arazi kullanımı arasındaki sosyo-ekonomik, insani-kurumsal ve biyofiziksel ilişkileri içerir ve yüksek ve aşağı havza alanları arasındaki bağlantıyı da göz önünde bulundurur (Ffolliott, 2002).

1.6.3. Coğrafi Bilgi Sistemi (CBS)

Dünya üzerindeki karmaşık sosyal, ekonomik, çevresel vb. sorunların çözümüne yönelik mekana veya konuma dayalı karar verme süreçlerinde kullanıcılara yardımcı olmak üzere, büyük hacimli coğrafi verilerin; toplanması, depolanması, işlenmesi, yönetimi, mekansal analizi, sorgulaması ve sunulması fonksiyonlarını yerine getiren donanım, yazılım, personel, coğrafi veri ve yöntem bütünüdür (Bkz. Şekil 1.1) (Ershad & Ali, 2020).

Coğrafi Bilgi Sistemlerinin kabiliyetleri şu şekilde ifade edilebilir: Büyük miktarlarda bilgiyi toplama, saklama, geri getirme ve analiz etme kabiliyeti, coğrafi bilgiler (harita) ile coğrafi olmayan bilgiler (bilgi tabloları) arasında iletişim kurabilme ve coğrafi bilgileri coğrafi olmayan bilgileri kullanarak analiz etmek için olanaklar yaratma kabiliyeti, geniş bir analiz yelpazesi gerçekleştirme kabiliyeti (örneğin: katmanları üst üste koymak, belirli bir nesneye yakınlık özelliğini kullanarak farklı nesneleri bulmak, simülasyon, belirli bir noktadan belirli bir mesafede bir olayın kaç kez meydana geldiğini hesaplamak), doğruluk, verimlilik, çalışma hızı ve veri güncelleme kolaylığına sahip olmak, belirli bir olgunun alanını ve çevresini hesaplamak gibi istatistiksel hesaplamaları gerçekleştirme kabiliyeti, zaman içinde coğrafi konumlarda meydana gelen değişiklikleri izleme ve gözden geçirme kabiliyeti ve farklı projelerin yerini belirlemek için kullanılır (Ershad & Ali, 2020).



Şekil 1.1. Coğrafi bilgi sisteminin temel bileşenleri (Ershad & Ali, 2020)

1.6.4. Uzaktan algılama


Uzaktan algılama, doğrudan temas olmaksızın bir nesnenin veya olgunun özelliklerini belirleyebilen, ölçebilen ve analiz edebilen teknoloji ve bilim olarak tanımlanır (Navalgund et al., 2007).

Teknolojinin ilerlemesi ve uyduların ortaya çıkmasıyla birlikte insan toplulukları, uzaktan algılama adı verilen yeni bir bilim biçiminde dünya manzaralarını izlemek için hava fotoğrafçılığına, uydu görüntülerine ve hava görüntülerine yöneldiler (Navalgund et al., 2007).

Uzaktan algılama, çeşitli olayların elektromanyetik yansımalarındaki değişiklikleri ve farklılıkları kaydetmeye dayandığından, toprak, kaya, bitki vb. türleri de dahil olmak üzere dünya olaylarının sınırlarını belirlemek mümkündür. Görüntülerinin ana avantajı, bunları bilgisayar tarafından analiz edilebilen ve farklı zamanlarda erişilebilen dijital olarak kullanma yeteneğidir (Loisel et al., 2009).

Uzaktan algılama ana bileşenleri: veri toplama bölümü (Enerji kaynağı, atmosfer, sensörler, nesneler ve olaylar.) ve toplanan verilerin işlenerek bilgi çıkarımı bölümü.

Şekil 1.2, dünya kaynaklarının elektromanyetik uzaktan algılanmasındaki genel süreci ve etkili unsurlarını şematik olarak göstermektedir.



Şekil 1.2. Uzaktan algılamanın genel süreci ve etkili unsurları (Ouattara et al., 2004)

A: Enerji kaynağı

B: Atmosfer yoluyla elektromanyetik enerjinin yayılması

C: Dünyanın yüzey etkileri ile çarpışmadan kaynaklanan enerji etkileşimleri

D: Hava veya uzay göstergeleri

E: Edinilen bilgilerin aktarımı

F: Birincil bilgilerin alınması ve verilerin dijital veya grafiksel olarak üretilmesi

G: Sensörden elde edilen verilerin analiz edilmesi amacıyla çeşitli görsel ve bilgisayar araçları kullanılarak verilerin incelenmesi ve yorumlanmasını içeren veri analizi süreci (Ouattara et al., 2004).

Uzaktan algılamanın birçok bilimsel ve araştırma alanında geniş uygulamaları vardır. Uzaktan algılama teknolojisinin uygulamaları arasında jeoloji, hidroloji, madencilik, haritacılık, biyolojik çalışmalar, çevre çalışmaları, Coğrafi Bilgi Sistemleri, meteoroloji, tarım, ormancılık, arazi geliştirme ve genel olarak arazi kaynaklarının yönetiminden yer almaktadır. Uzaktan algılama, dünya yüzeyindeki olaylardaki periyodik değişiklikleri gösterebilmektedir ve nehirlerin yataklarının değişiminin incelenmesi, göl, deniz ve okyanus gibi su kütlelerinin sınırlarının değiştirilmesi, morfolojinin değiştirilmesi gibi durumlarda oldukça etkilidir. Ayrıca çeşitli olayların elektromanyetik yansımadaki değişiklik ve farklılıkların kaydedilmesine dayalı olarak çalışan bir uzaktan algılama sistemi, farklı toprak, kaya, bitki türlerinin sınırları da dahil olmak üzere karasal olayların sınırlarını çeşitli tarım ürünleri belirleyebilir (Kupfer & Emerson, 2005).

Hava durumunu tahmin etmek ve doğal afetlerin neden olduğu hasar miktarını ölçmek, deniz yüzeyindeki su kirliliğini ve yağ lekelerini tespit etmek ve maden keşiflerinde de uzaktan algılamadan yararlanılmaktadır. Kuşkusuz bu teknolojinin keşif çalışmalarında ve doğal kaynaklarda ve yukarıda belirtilen diğer durumlarda kullanılması, çalışmaların hızını arttırdığı gibi doğruluk, maliyet ve insan gücü açısından da çok daha ekonomiktir (Kupfer & Emerson, 2005).

1.6.5. Havza yönetiminde uzaktan algılama uygulaması

Havza yönetimi günümüzde, artan su talebi ve iklim değişikliğinden kaynaklanan zorluklarla birlikte hayati öneme sahiptir. Uzaktan algılama ve Coğrafi Bilgi Sistemleri, bu kritik göreve önemli katkılarda bulunmaktadır (Rango, 1975):

- Arazi kullanımı ve arazi örtüsü haritalaması

Doğru arazi kullanımı ve arazi örtüsü haritalaması bir havzanın dinamiklerini anlamak için temel öneme sahiptir. Uzaktan algılama, arazi kullanımındaki değişiklikleri zaman içinde kategorize etmemize ve izlememize olanak sağlamaktadır. Bu veriler havzadaki kentsel planlama, tarım ve koruma çabaları için çok değerlidir. Bu teknolojinin nasıl kullanıldığına dair bir örnek, artan akışa veya kirliliğe yol açabilecek arazi kullanımı değişikliklerinin tespitinde görülebilir. Uydu görüntüleri ve makine öğrenimi algoritmaları gibi araçlar kullanılarak arazi kullanımındaki değişikliklerin izlenmesi ve olası sorunlara zamanında müdahale edilmesi mümkün hale gelmektedir.

- Su Kalitesi Değerlendirmesi

Su kalitesinin korunması, ekosistemlerin saęlıęı ve insan popölasyonlarının refahı için çok önemlidir. Uzaktan algılama, bulanıklık, klorofil konsantrasyonu ve sıcaklık gibi su kalitesi parametrelerinin deęerlendirilmesinde çok önemli bir rol oynar. Uydular ve dronlar üzerinde bulunan çeşitli sensörler, su kaynaklarının saęlıęı hakkında önemli veriler sağlayabilir. Bu sensörler, su kirlilięi kaynaklarını belirlemek, alg çoęalmalarını izlemek ve su kütlelerinin genel saęlıęını deęerlendirmek için kullanılabilir.

- Toprak nemi analizi

Topraęın nem içerięi havza yönetiminde kritik bir faktördür. Bitkiler için suyun kullanılabilirlięini, yeraltı suyunun beslenmesini ve toprak erozyonu olasılıęını etkiler. Mikrodalga ve kızılötesi sensörlerle donatılmış uzaktan algılama cihazları, geniş alanlarda toprak nem seviyelerini ölçebilir. Bu veriler tarımda sulama uygulamalarının optimize edilmesi, kuraklık koşullarının yönetilmesi ve toprak erozyonunun önlenmesi açısından çok deęerlidir.

- Topografik ve morfometrik analiz

Bir havzanın topografyasını ve morfometrisini anlamak taşkın modellemesi, erozyon kontrolü ve sürdürülebilir arazi kullanımı planlaması için hayati öneme sahiptir. Uzaktan algılama teknolojisi, yüksek doğrulukta topografik haritalamaya olanak tanır. Havza yöneticileri, ayrıntılı yükseklik verileriyle taşkın yataęı haritaları oluşturabilir, arazi stabilitesini deęerlendirebilir ve toprak kaymasına yatkın alanları belirleyebilir.

- Bitki örtüsü analizi

Bitki örtüsü havza yönetiminde çok önemli bir rol oynamaktadır. Topraęı stabilize eder, erozyonu azaltır ve ekosistemin genel saęlıęını etkiler. Uzaktan algılama araçları, bitki örtüsü yoğunluęu, tür dağılımı ve zaman içindeki deęişiklikler hakkında bilgi sağlar. Havza yöneticileri, bitki örtüsünün saęlıęını ve deęişikliklerini izleyerek yeniden ağaçlandırma çabalarını uygulayabilir, istilacı türleri kontrol edebilir ve havzanın ekolojik dengesini etkileyen arazi yönetimi uygulamaları hakkında bilinçli kararlar alabilirler.

- Taşkın tahmini ve yönetimi

Havza yönetiminde uzaktan algılamanın en kritik uygulamalarından biri taşkın tahmini ve yönetimidir. Gelişmiş radar ve uydu teknolojisi, yağış ve su seviyelerinin gerçek zamanlı izlenmesini sağlar. Yetkililer bu verileri hidrolojik modellerle entegre ederek erken uyarılar verebilir ve sel hasarını azaltmak, hayatları korumak ve mal kaybını azaltmak için bilinçli kararlar alabilirler.

- Yeraltı suyu potansiyeli imarı

Yeraltı suyunun mevcudiyeti bir havzadaki birçok topluluk için önemlidir. Uzaktan algılama, yeraltı suyu potansiyelinin bölgelere ayrılmasına, akifer potansiyeli yüksek olan ve tükenme riski taşıyan alanların belirlenmesine yardımcı olabilir. Bu bilgi, hem kentsel hem de kırsal alanlar için sürekli ve güvenilir bir su kaynağı sağlayarak sürdürülebilir yeraltı suyu yönetimi uygulamalarına rehberlik etmektedir.

- Kuraklık izleme

Kuraklığa duyarlı bölgelerde, su kaynaklarının etkin bir şekilde yönetilmesi büyük önem taşır. Bu tür bölgelerde, zamanında ve doğru bilgiye erişim, su kaynaklarının sürdürülebilir kullanımı için hayati önem taşır. Uzaktan algılama, yağış seviyeleri, toprak nemi, bitki örtüsü sağlığı gibi su kaynaklarının izlenmesi için kritik olan temel göstergelerin belirlenmesine yardımcı olur. Bu teknoloji, geniş alanlardaki değişiklikleri hızlı bir şekilde tespit etme ve izleme yeteneği sağlar. Havza yöneticileri, uzaktan algılama verilerini kullanarak su koruma önlemlerini uygulamak, kaynakları kuraklıktan etkilenen bölgelere tahsis etmek ve su kıtlığına karşı uzun vadeli dayanıklılık planlamak için kullanabilirler.

- Sediment verimi tahmini

Erozyon ve çökeltme, su kaynaklarının kalitesini etkileyen önemli faktörlerdir ve su yollarının tıkanmasına neden olabilir. Uzaktan algılama ve Coğrafi Bilgi Sistemleri (CBS), toprak erozyonu oranlarını izlemek ve tortu veriminin tahmin edilmesine yardımcı olmak için güçlü araçlar sunar. Bu bilgi, erozyon kontrol önlemlerinin tasarlanması ve uygulanması, sediman tutma yapılarının yerleştirilmesi ve havzaların bütünlüğünün korunması gibi çeşitli alanlarda kritik öneme sahiptir.

- İklim değişikliği etki değerlendirmesi

İklim değişikliği yağış düzenlerini değiştiriyor ve hava olaylarını yoğunlaştırarak dünya çapında su havzalarını etkiliyor. Uzaktan algılama, bu değişiklikleri ve bunların su kaynakları üzerindeki etkilerini değerlendirmek için kritik veriler sağlar.

- Orman yangını algılama ve yönetimi

Havzalar genellikle orman yangınlarına karşı savunmasız olan geniş ormanlık alanları kapsar. Kızılötesi sensörler ve termal görüntülemeyi içeren uzaktan algılama teknolojisi, orman yangınlarının erken tespitini kolaylaştırır. Yetkililer, yangınları başlangıç aşamalarında tespit ederek hızlı bir şekilde müdahale ederek ekosistemlere ve su kalitesine verilen zararı en aza indirebilirler.

- Yağış-Akış modellemesi

Yağış ve yüzey akışı arasındaki ilişkinin ölçülmesi, taşkın tahmini ve su kaynaklarının yönetimi açısından önemlidir. Uzaktan algılama verileri, yağışın yüzey akışına nasıl dönüştüğünü simüle eden hidrolojik modellere beslenir. Bu modeller bir havzadaki akış dinamiklerinin anlaşılması ve taşkın kontrol altyapısının tasarlanması için vazgeçilmezdir.

1.6.6. Arazi kullanım değişikliği

Arazi kullanım değişikliği, belirli bir arazi parçasının kullanımının veya yönetiminin değişmesini ifade eder. Bu değişiklik sadece arazi türünde bir değişiklik anlamına gelmez, aynı zamanda arazi yoğunluğu, kullanımı ve yönetimi gibi faktörlerde de değişiklikler içerebilir. Bu değişiklikler genellikle karmaşık etkileşimlerin sonucudur ve siyaset, yönetim, ekonomi, kültür, insan davranışlı ve çevre gibi birçok faktörün bir araya gelmesiyle ortaya çıkar (Lambin et al., 2001).

Arazi kullanımı, insan faaliyetlerinin gerçekleştiği coğrafi alanların dağılımını ifade eder. Bu faaliyetler arasında üretim, tüketim, yatırım, eğlence ve diğerleri bulunur. Dolayısıyla, arazi kullanımındaki değişim, büyüme ve kalkınma gibi faktörlerin etkisiyle ortaya çıkabilir. Ancak, bu değişimlerin yönetimi ve kontrolü önemlidir çünkü yanlış yönlendirilmiş arazi kullanımı, en verimli toprakların zarar görmesine, tarımsal kayıplara, doğal manzaraların tahrip olmasına ve yeraltı suyunun aşırı kullanımına neden olabilir (Maitima et al., 2010).

1.6.7. Arazi kullanım planlaması

Arazi kullanım planlaması, topluluğun istek ve ihtiyaçlarına göre faaliyetlerin mekansal olarak organize edilmesi anlamına gelir. Bu planlama uygulamada, arazi kullanım türlerini sınıflandırır ve konumlandırırken, aynı zamanda yatırımlar ve kamu kararları üzerinde büyük etkisi olan sosyal, ekonomik ve fiziksel hedeflere ulaşmak için önemli araçlardan biridir. Ayrıca, fiziksel çevrenin büyüme hızı ve kalitesinde de önemli bir rol oynar (Paine & Kiser, 2012).

Arazi kullanım planlaması, yaşamın farklı kullanımları için araziye ve mekanı bölme bilimidir. Bu planlama, insan faaliyetlerinin dağılım modelini optimize etmek için akıllıca bir alan yönetimidir ve aynı zamanda gelecekteki arazi kullanım modellerinin nasıl gerçekleştirileceğine dair sosyal niyetlerin bir ifadesidir. Bu nedenle, belirli arazi kullanımı türlerine ve her katman için kullanım yoğunluğuna ve yoğunluğuna tahsis edilmesi gereken alanları belirler. Ayrıca, çeşitli genel kullanımları ve bu alanların

geliştirilmesi ve bakımında kullanılması gereken ilke ve standartları belirler. Arazi kullanım planlaması, toplumun ihtiyaçlarını karşılamak için arazi kaynaklarını en verimli şekilde kullanmayı amaçlar ve bu süreç, çeşitli paydaşların katılımını ve mekansal kaynakların sürdürülebilir yönetimini gerektirir (Rufino et al., 2019).

1.6.8. Değişim analizi

Değişim analizi, farklı zamanlarda gözlemlenen olay ya da objelerin durumlarındaki farklılıkların tanımlanması olarak ifade edilir. Bu analiz, farklı zamanlarda çekilmiş aynı bölgeye ait iki uydu görüntüsü arasında meydana gelen değişiklikleri tespit etmeyi amaçlar. Son yıllarda, uzaktan algılama verileri ve CBS, dünyanın farklı bölgelerinde arazi kullanım değişikliğini ve arazi örtüsünü belirlemek ve analiz etmek için yaygın olarak kullanılmaktadır (Wijesinghe & Withanage, 2021).

1.6.9. Görüntü sınıflandırması

Görüntü sınıflandırma, büyük uydu görüntülerinden değerli bilgilerin çıkarılması amacıyla görüntü piksel değerlerinin anlamlı kategorilere veya arazi örtüsü sınıflarına ayrılması işlemidir. Uzaktan algılama bağlamında, bir piksel, bir sayısal görüntü veri setinin bir numarasına karşılık gelen bir zemin alanıdır. Görüntü sınıflandırmasının temel fikri, dünya yüzeyindeki farklı özelliklerin farklı bir spektral yansımaya sahip olmasıdır. Görüntü sınıflandırma, uzaktan algılanan verilerden değerli bilgilerin çıkarılmasına yardımcı olduğundan, CBS ve uzaktan algılamada kritik bir rol oynar (Lillesand et al., 2015).

Bu teknik, arazi kullanımı ve arazi örtüsü haritalaması, kentsel planlama, tarımın izlenmesi, doğal kaynak yönetimi ve çevre çalışmaları gibi çeşitli amaçlar için kullanılabilen bilgilerin elde edilmesini sağlar. Görüntü sınıflandırması, pikselleri farklı sınıflara ayırarak verileri basitleştirir ve kullanıcıların mekansal modelleri, eğilimleri ve ilişkileri analiz etmesini ve anlamasını kolaylaştırır. Bu sayede, CBS ve uzaktan algılama alanındaki uzmanlar, karar alıcılar ve araştırmacılar, karmaşık çevresel sorunları anlamak ve çözmek için değerli bilgilere erişebilirler (Lillesand et al., 2015)

2. LİTERATÜR ÖZETİ

Literatür özeti bölümünde, tez konusu ile ilgili önceki araştırmalar incelenmiş ve bu çalışmaların sonuçları özetlenmiştir.

Alavi Panah vd., (2001), Yezd ilinin Ardakan bölgesi ve Fars eyaletindeki Mook bölgesindeki arazi kullanımı haritalaması için eylül ve ekim 1990'da kaydedilen Landsat TM görüntüleri kullanılmıştır. Bu çalışmada, termal bantın kabiliyeti değerlendirilmiştir. Bant kombinasyonlarına termal bant dahil edilerek Maksimum Olabilirlik yöntemi kullanılmıştır. Görüntü sınıflandırmalarının sonuçlarına göre, TM6 (Landsat TM termal bantı) Ardakan'da sınıflandırma doğruluğunu artırmıştır, ancak Mook bölgesinde belirgin bir etkisi olmamıştır. Sonuçlara dayanarak, TM bantlarının sınıflandırma etkinliğinin arazi örtüsü tipine, iklim koşullarına ve coğrafi faktörlere bağlı olarak değişebileceği sonucuna varılmıştır.

Southworth (2004) Meksika'nın Yucatan eyaletindeki tropikal kuru ormanların bulunduğu bir bölgede, Landsat TM termal bant verilerinin arazi örtüsü sınıflandırması için kullanılan bir teknik incelenmiştir. Bu çalışmada, bant 6'nın (termal bant) kuru tropikal orman ekosistemindeki arazi örtüsü sınıflarının ayrımı için önemli bilgiler içerdiği tespit edilmiştir. Diskriminant analizi sonuçlarına göre, bant 6, farklı arazi örtüsü sınıflarını ayırmak için 0.35 katsayısı ile önemli bilgiler sağlamıştır.

Oruc vd. (2004) Türkiye'deki Zonguldak bölgesi için arazi kullanım haritasını oluşturmak için Landsat 7 ETM+ uydu görüntülerini kullanan temel ve nesne tabanlı piksel yöntemlerini değerlendirmiştir. Çalışmada temel piksel yöntemi olarak Minimum Mesafe, Paralel Düzlem ve Maksimum Olasılık algoritmaları kullanılmıştır. Ardından, ecognition yazılım ortamında nesne tabanlı sınıflandırma için en yakın komşu yöntemi uygulanmıştır. Sonuçlar, nesne tabanlı sınıflandırma yönteminin, temel piksel yöntemlerinden daha doğru olduğunu göstermiştir.

Abdulaziz (2009) Doğu Nil Deltası bölgesinin çöl kenarlarında, 1984, 1990 ve 2003 tarihli Landsat TM ve ETM+ görüntüleri kullanılarak üç farklı arazi kullanımı haritası üretmiştir. Arazi örtüsü sınıflandırması için hibrit bir sınıflandırma yöntemi kullanılmıştır. Kontrollü sınıflandırma için Maksimum Olabilirlik sınıflandırıcısı ve kontrolsüz sınıflandırma için ISODATA kümeleme yöntemi kullanılmıştır. Elde edilen arazi örtüsü haritalarının genel doğruluğunu artırmak için sınıflandırma sonrası iyileştirme işlemi uygulanmıştır. Hibrit sınıflandırma yöntemiyle 1984, 1990 ve 2003

yıllarına ait üç arazi örtü haritası oluşturulmuştur. Çalışmanın sonuçları, tarımsal gelişmenin çalışma süresi boyunca %14 arttığını göstermiştir.

Schulz vd. (2010) merkezi Şili'deki arazi örtüsü değişikliklerini, 1975, 1985, 1999 ve 2008'de alınan uydu görüntülerini kullanarak araştırmışlar. Ortaya çıkan sekiz arazi örtüsü sınıfının sınıflandırılması için Maksimum Olabilirlik algoritması kullanılmıştır. Ormanlar ve kereste plantasyonları ile çıplak arazi ve kentsel sınıflar arasında daha iyi ayırım yapmak için, yardımcı veriler kullanılarak sınıflandırma sonrası işleme uygulanmıştır. Ortalama net yıllık ormansızlaşma oranı %1,7 ve çalılık alanlarındaki azalma yıllık %0,7 oranında olduğunu gösterilmiştir.

Zhaohua Chen (2010), 1987-2006 döneminde Hubei eyaletinin Zigui ilçesinde arazi kullanımı değişikliklerini tespit etmek için optik uydu görüntüleri kullanmıştır. Çalışmada Landsat-5 TM (1987), Landsat 7 (2002), Aster (2003), Chris-Proba (2006) ve 90m çözünürlüğünde bir DEM verileri kullanılmıştır. Karar kuralına dayalı sınıflandırma yöntemi kullanılarak yaptığı çalışmada, yedi farklı sınıf için elde edilen LU/LC haritalarının genel doğrulukları %73.4 ile %89.5 arasında değiştiğini göstermiştir. Ayrıca, orman, çalı ve çimen gibi doğal bitki örtülerinin yaklaşık %32'sinin yerleşim alanları, tarım arazileri ve meyve bahçeleri gibi kullanım alanları nedeniyle kaybedildiğini gösterilmiştir.

Otukei ve Blaschke (2010), 1986 ve 2001 yıllarına ait Landsat TM ve ETM+ veri kümelerinin analizi için Karar Ağaçları yönteminin potansiyeli incelemiştir. Orijinal Landsat TM bantlarının yanı sıra, analiz için orijinal verilerden türetilmiş bir dizi bant kullanılmıştır. Bu bantlar arasında ilk üç temel bileşen (PC), ilk üç tasselled cap (TC) dönüştürülmüş bantlar, normalleştirilmiş bitki örtüsü indeksi (NDVI) ve spektral varyansa dayalı doku bantı bulundurulmuştur. Genel olarak, tüm durumlarda %85'in üzerinde kabul edilebilir doğruluklar elde edilmiş ve Karar Ağaçları, Makine Öğrenmesi Tabanlı Sınıflandırma (MLC) ve Destek Vektör Makineleri (SVM) modellerinden daha iyi performans sergilediği belirlenmiştir.

Da vd. (2012) toprak sınıflarının tahmininde iki farklı sınıflandırıcının olarak, Yapay Sinir Ağları ve Maksimum Olabilirlik algoritması uygulanabilirliğini Rio De Janeiro eyaletinin kuzeybatısındaki değerlendirmiştir. Yükseklik, eğim, bakı ve bileşik topografik indeks (CTI) gibi arazi nitelikleri ve kil mineralleri indeksleri, demir oksit ve Landsat 7 ETM+ sensör görüntüsünden türetilen Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), ayırt edici değişkenler olarak kullanılmıştır. İstatistiksel testlere göre,

Yapay Sinir Ağlarına dayalı sınıflandırıcının doğruluğu, klasik Maksimum Olabilirlik sınıflandırıcısından daha yüksek olduğu gösterilmiştir.

Poursanidis vd. (2015) OLI ve TM arasındaki farklılıkları değerlendirmek için görüntü sınıflandırma yöntemlerinin performanslarını karşılaştırmak amacıyla, piksel tabanlı MLC ve SVM yöntemlerini kullanmıştır. Landsat OLI'den elde ettiği sınıflandırma sonuçları, Landsat TM'ye kıyasla daha doğru sonuçlar sağlamıştır. Genel doğruluk, Landsat 8'in SVM piksel tabanlı sınıflandırmasının, orta mekansal çözünürlüklü görüntülerle kentsel arazi örtüsünün haritalanmasında en doğru olduğunu kanıtlanmıştır.

Qian vd. (2015) 2012'de elde edilen WorldView-2 uydu görüntülerini sınıflandırmak için, Destek Vektör Makinesi (SVM), Normal Bayes (NB), Sınıflandırma ve Regresyon Ağacı (CART) ve KNN gibi dört makine öğrenme sınıflandırıcısının performansını nesne tabanlı sınıflandırma prosedürü kullanılarak değerlendirmiş ve karşılaştırmıştır. SVM ve Naive Bayes (NB), CART ve KNN yöntemlerinden daha üstün olduğunu ve her ikisinin de %90 üzerinde doğruluğa sahip olduğunu göstermiştir. Ayrıca, özellikle en yaygın olarak kullanılan SVM sınıflandırıcısı için, ayar parametrelerinin ayarlanmasının sınıflandırma doğruluğunu büyük ölçüde etkilediği ve eğitim örneklerinin boyutunun artırılmasının genellikle dört sınıflandırıcının tümü için sınıflandırma doğruluğunu artırdığı gösterilmiştir.

Lee vd. (2015) kentsel alanların arazi örtüsü sınıflandırmasının doğruluğunu iyileştirmek için, Landsat 8 TIR bant görüntülerinin kullanımının etkinliğini araştırmıştır. Farklı bant kombinasyonları kullanılarak yapılan sınıflandırma sonuçlarına göre, TIR bantının görünür ve yakın kızılötesi bantlara eklendiği bir görüntü kullanılarak yapılan sınıflandırma doğruluğu, TIR bant kullanılmayan bir bant kombinasyonu ile yapılan sınıflandırmaya kıyasla %4,0 oranında iyileştirilmiştir. Özellikle kentsel alan arazi kullanımı sınıflandırması için, üreticinin doğruluğu ve kullanıcının doğruluğu değerleri sırasıyla %10,2 ve %3,8 oranında iyileştiği gösterilmiştir.

Mushore vd. (2017) Landsat 8 sensörünün termal bantlarını ve türetilmiş bitki örtüsü indekslerini kullanarak, Destek Vektör Makinesi sınıflandırıcısını karmaşık bir kentsel peyzajda arazi örtüsü sınıflandırmasını iyileştirmenin potansiyelini araştırmışlardır. Landsat 8'in kentsel arazi kullanımı sınıflandırmasında yansıtıcı, termal bantlar ve bitki örtüsü indekslerinin bireysel ve birleşik performansını karşılaştırılmıştır. Landsat 8'in yansıtıcı bantlarının, türetilmiş bitki örtüsü indekslerinin ve genel olarak

termal bantların entegrasyonu, geleneksel bantların bağımsız olarak kullanılmasına göre önemli ölçüde daha yüksek doğrulukta sınıflandırma sonuçları üretilmiştir. Ayrıca, Landsat 8'in OLI ve TIR verilerinin entegrasyonunun, karmaşık bir kentsel peyzajda doğru ve güvenilir arazi örtüsü sınıflandırması için önemli bir potansiyel sunduğunu gösterilmiştir.

Thanh Noi ve Kappas (2017) Sentinel-2 görüntü verilerini kullanarak, arazi kullanımı sınıflandırması için RF, KNN ve SVM yöntemlerin performanslarını karşılaştırmışlar. Vietnam'ın Kızıl Nehir Deltası'nda, altı farklı arazi kullanımı tipine sahip 30×30 km²'lik bir alanı, 14 farklı eğitim örnekleme büyüklüğü kullanarak sınıflandırma yapılmıştır. Tüm sınıflandırma sonuçları, %90 ile %95 arasında değişen yüksek bir genel doğruluk göstermiştir. Üç sınıflandırıcı ve 14 alt veri kümesi arasında, eğitim örneklem boyutlarına en az duyarlı olan en yüksek genel doğruluk oranını SVM sınıflandırıcısının ürettiğini ve bunu sırasıyla RF ve KNN izlediğini kanıtlanmıştır.

Lossou vd. (2019) Gana'nın Goaso Orman Bölgesi'nin yönetimi altındaki tropikal yüksek ormanlardaki sekiz orman rezervinin durumunu değerlendirmek için, 1990 (TM), 2013 (ETM+) ve 2017 (OLI_TIRS) Landsat verileri kullanılarak Maksimum Olabilirlik algoritmasıyla kapalı gölgelik orman, açık gölgelik orman, çıplak arazi, tarım arazisi ve bozulmuş arazi olarak sınıflandırılmıştır. Daha sonra, çalışma süresi boyunca meydana gelen değişiklikleri analiz etmek için sınıflandırma sonrası değişiklik tespit teknikleri kullanılmış ve sonuçta kapalı gölgelik ormanların yaklaşık %37,63'ünün diğer örtü türlerine dönüştürüldüğü gösterilmiştir.

Zhao vd. (2019) Mısır'daki bir alandaki arazi örtüsünü haritalamak için, Landsat 8'in termal bantını kullanan ve kullanmayan farklı uzaktan algılama özelliklerinin kombinasyonlarını karşılaştırmıştır. Termal özelliğin arazi örtüsünün haritalanması üzerinde olumlu bir etkisi olduğunu belirlenmiştir. Spektral özellikler, indeksler ve termal özelliğin bir kombinasyonunun, doğruluğu en üst düzeye çıkardığını gösterilmiştir. Önerdikleri sınıflandırıcı, termal özelliğin ekili alan ve sulak alan arasındaki karışıklığı önemli ölçüde azaltmıştır. Ayrıca, farklı arazi örtüsü türleri arasında sıcaklık değişimleri meydana geldiğinde termal özelliğin sınıflandırma doğruluğunu artırdıklarını belirtmiştir.

Ha vd. (2020) Vietnam'ın Thai Nguyen eyaletindeki kentsel genişlemenin ve arazi kullanımı değişikliğinin zamansal ve mekansal özelliklerini haritalamak ve izlemek için, R programlamada Rastgele Orman yöntemini kullanmıştır. Kontrolsüz sınıflandırmalara, bant kompozitlerine ve NDVI hesaplamasına dayalı olarak yedi arazi örtüsü sınıfını (inşa

edilmiş arazi, tarım arazisi, orman arazisi, su kütleleri, maden, çalı arazisi ve çay plantasyonu) tanımlanmıştır. Sonuçlar, 2000 ve 2016 yılları arasında önemli ve düzensiz bir kentsel büyüme ve önemli bir orman ve ekili alan kaybı olduğunu göstermiştir.

Elagouz vd. (2020) 1987'den 2015'e kadar Mısır'ın Nil Deltası'ndaki farklı arazi kullanım sınıflarındaki değişiklikleri, üç farklı tipte Landsat görüntüsü (Landsat 5 TM, Landsat 7 ETM+ ve Landsat 8 OLI TIRS) kullanarak değerlendirmiştir. Çalışma alanında bulunabilecek sınıfları belirlemek için, ISODATA algoritmasıyla kontrolsüz bir sınıflandırma yapılmış ve daha sonra Destek Vektör Makinesi (SVM) tekniğine dayalı kontrollü bir sınıflandırma gerçekleştirilmiştir. Sonuçlar, incelenen alanda tarımsal, kentsel, balık çiftlikleri ve doğal bitki örtüsü alanlarında sürekli bir artış ve su kütlelerinde ve kum alanlarında sürekli bir azalma tespit edildiğini göstermiştir.

Kumar vd. (2020) Haridwar bölgesinde multispektral Landsat-8 OLI, Landsat-7 ETM+ ve Landsat-5 TM uydu görüntü verileri kullanarak, arazi kullanım değişimi değerlendirmiştir. Çalışmada 1996, 2003, 2010 ve 2017 yıllarına ait uydu verileri kullanılmış ve çalışma alanı yedi farklı arazi kullanım sınıfına ayrılmıştır. Maksimum Olabilirlik Sınıflandırıcısı kullanılarak %81.55, %86.86, %80.67 ve %93.00 doğruluk elde edilmiştir. Haridwar bölgesinde 1996'dan 2017 yılına kadar meyve bahçelerinin 11806 ha (%9,82) azaldığını ve kentleşme ve sanayileşme nedeniyle kentsel ve tarım arazilerinde kalıcı olarak dönüştüğü gösterilmiştir.

Mishra vd. (2020) Sikkim Himalaya'nın Rani Khola Havzası'nın arazi örtüsü haritalarını, 1988–1996, 1996–2008 ve 2008–2017 dönemleri için üretmiştir. Bu haritalar için Landsat-5 TM ve Sentinel-2A MSI verilerinden görüntüler kullanılmıştır. Maksimum Olabilirlik Sınıflandırıcısı kullanılarak su havzasının arazi kullanım haritaları hazırlanmıştır. Çalışmada altı ana arazi kullanım sınıfı tespit edilmiştir. Sonuçlara göre, yoğun orman, yerleşim alanı ve su kütlelerinin sırasıyla %16.40, %2.13 ve %0.11 oranında arttığı gözlemlenmiştir. Açık orman, tarım arazileri ve çorak arazilerin ise sırasıyla %-13.98, %2.83 ve %-1.82 oranında azaldığı tespit edilmiştir.

Tadesse vd. (2020) uzaktan algılama ve Coğrafi Bilgi Sistemi kullanarak Awash Nehir Havzası'ndaki arazi kullanımı değişikliklerinin ve nüfus artışının uzun vadeli dinamiklerini analiz etmişlerdir. 1988, 2002 ve 2018 için Landsat görüntüleri kullanarak altı arazi kullanım sınıfı belirlenmiştir. Maksimum Olabilirlik algoritması kullanılmıştır. Genel doğrulukları 1988 ve 2002 için %86,9 ve %88,7 olarak belirlenmiş ve 2018 görüntüleri için ise Kappa katsayılarını sırasıyla 0,83 ve 0,88 olarak belirlenmiştir.

Yang vd. (2021) Qilian Dağları'ndaki arazi kullanımını haritalamak için, Google Earth Engine (GEE) platformuna dayalı farklı uzaktan algılama sınıflandırma algoritmalarının performansını incelemişlerdir. Sentinel-1 ve Sentinel-2'nin daha yüksek mekansal çözünürlüklü uzaktan algılama görüntüleri ile dijital yükseklik verileri kullanılarak Qilian Dağları'nın sınıflandırılması için üç farklı uzaktan algılama sınıflandırma algoritması uygulanmıştır. Sonuçlar, farklı uzaktan algılama sınıflandırma algoritmalarının farklı doğruluk oranlarına sahip olduğunu ve Rastgele Orman'nin en yüksek doğruluk oranına sahip olduğunu, CART ve SVM'nin ise RF'yi takip ettiğini göstermiştir.

Asare vd. (2021) Bosumtwi Havzası'ndaki arazi kullanım değişimini sırasıyla 1986, 2007 ve 2018 yıllarında incelemek için Landsat TM, ETM+ ve Sentinel-2A uydu görüntüleri kullanarak Maksimum Olabilirlik algoritmasını kullanmışlardır. Ayrıca, eğitim alanlarının sınırlandırılması ve doğruluk değerlendirmesi için Google Earth'ten yüksek çözünürlüklü görüntüler ve GPS'ten yardımcı veriler kullanarak gölün yüzey alanının %3,7 oranında küçüldüğünü belirlenmiştir. 1986 ile 2018 yılları arasında tarım arazileri ve yerleşim alanlarının sırasıyla yıllık %5,2 ve %5,4 oranında arttığını, kapalı orman, açık orman ve gölün yüzey alanının ise sırasıyla %1,3, %0,8 ve %0,1 oranında küçüldüğünü belirlenmiştir.

Bonansea vd. (2021) Arjantin'deki Los Molinos rezervuarının havzasındaki arazi kullanım değişiminin ve rezervuarın, su kalitesi ile ilişkisini araştırmışlardır. İncelenen havzadaki arazi kullanım değişimini analiz etmek için, 1990'dan 2020'ye kadar Landsat 5 (1990), Landsat 7 (2001), 2010 ve Landsat 8 (2020) görüntülerini kullanılmış ve sınıflandırma için Destek Vektör Makinesi algoritmasını tercih edilmiştir. Sonuçlar, en önemli arazi kullanım değişikliğinin yirmi yıl önce başladığını ve son on yılda yoğunlaştığını göstermiştir. İşlenen tüm görüntüler, sınıflandırma prosedüründe 0,88'den yüksek bir kappa katsayısı belirlenmiştir.

Edan vd. (2021) Al Kut, Irak'ta arazi kullanım değişimini haritalamak için, 2000, 2010 ve 2020 yıllarına ait Landsat TM ve OLI görüntüleri kullanmıştır. Arazi kullanım sınıflarını sınıflandırmak için, Destek Vektör Makine algoritması kullanılmıştır. Her yıl arazi kullanım sınıflarının sınıflandırılması için yaklaşık 200 eğitim örneği alınmıştır. 2000 ve 2010 sınıflandırılmış görüntülerin doğruluğunu için 300 nokta Google Earth'den ve 2020 yılı içinde Google Earth ve GPS'ten 150 nokta toplanmıştır. Sonuçlar, 2000'den

2020'ye kentsel alanda %8,74 oranında önemli bir artış ve yeşil örtüde %25,87 oranında azalma olduğunu göstermiştir.

Loukika vd. (2021) Hindistan'ın Aşağı Krishna havzasındaki Munneru alt havzasında, Google Earth Engine platformunda üç farklı makine öğrenimi algoritması olan Destek Vektör Makinesi (SVM), Rastgele Orman (RF) ve Sınıflandırma ve Regresyon Ağaçları (CART) kullanarak, LULC sınıflandırması yapmışlardır. Sınıflandırma doğruluğunu artırmak için NDVI ve NDWI indekslerini elde edip analize dahil edilmiştir. Sentinel-2 ve Landsat-8 verilerini, 2016, 2018 ve 2020 yılları için kullanılmıştır. Landsat-8 görüntüleri için SVM, RF ve CART sınıflandırıcılarının ortalama genel doğrulukları, sırasıyla %90.88, %94.85 ve %82.88 olarak belirlenmişken; Sentinel-2 görüntüleri için bu değerler sırasıyla %93.8, %95.8 ve %86.4 olarak tespit edilmiştir.

Basheer vd. (2022) tarafından yapılan çalışmada, Charlottetown şehri için ArcGIS Pro ve Google Earth Engine gibi iki yaygın olarak kullanılan platformları kullanarak farklı uydu veri setleriyle, arazi kullanımı ve arazi örtüsü (LULC) sınıflandırma performansını değerlendirmişlerdir. ArcGIS Pro'da SVM, ML ve RF gibi üç farklı sınıflandırıcı kullanılırken, Google Earth Engine'de SVM, RF, MD ve CART gibi dört farklı sınıflandırıcı tercih edilmiştir. Çalışmanın sonuçları, ArcGIS Pro ve Google Earth Engine'deki SVM sınıflandırıcısının diğerlerine göre en iyi performansı sergilediğini göstermiştir. SVM'in Landsat ile %89, Sentinel ile %91 ve Planet ile %94'lük bir doğruluk oranı sağladığı belirlenmiştir. Benzer şekilde, Google Earth Engine'deki SVM'in Landsat 8 ile %87 ve Sentinel 2 ile %92 doğruluk oranı sağladığı tespit edilmiştir.

Rana vd. (2022), Sonipat bölgesinde son on yılda (2011-2021) gerçekleşen arazi kullanımı dönüşümlerindeki değişiklikleri analiz etmiştir. Google Earth Engine (GEE) ve QGIS kullanılarak, Landsat 7 ve Sentinel 2 uydu görüntü koleksiyonları kullanılmıştır. En olası sınıflandırma yaklaşımı kullanılarak, çalışma alanı dört arazi kullanımı kategorisine ayrılmış ve belirtilen dönem boyunca meydana gelen değişiklikler nicelendirilmiştir. Sonuçlar, 2011-2021 arasında çalışma alanındaki tarım arazisinin yaklaşık %11 azaldığını, yapılaşma ve kentsel alanların ise %3 arttığını göstermiştir.

Arpitha vd. (2023) Karnataka eyaletindeki arazi kullanımı ve arazi örtüsünün sınıflandırılması için, Google Earth Engine (GEE) üzerinde üç farklı yöntemi kullanmıştır. Bu yöntemler, Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Sınıflandırma Regresyon Ağaçları (CART) gibi makine öğrenimi tekniklerini içermiştir.

Sınıflandırma doğruluğunu artırmak için, Normalleştirilmiş Farklılık Bitki Örtüsü İndeksi (NDVI) kullanılmıştır. 2015'ten 2021'e kadar olan süreçte LULC sınıflandırması için, Sentinel-2, Landsat-8 ve MODIS gibi çok zamanlı görüntülerden elde edilen verilerle çalışılmıştır. Çalışmanın bulgularına göre, tarım alanlarının değişim oranının 2015'ten 2021'e kadar yüksek olduğu ve bu da çalışma yılı boyunca yaklaşık %3.78 arttığı gösterilmiştir.

Ouchra vd. (2023) Fas'ın arazi örtüsü sınıflandırmasını gerçekleştirmek için Landsat 8 uydu verilerini kullanmıştır. Destek Vektör Makinesi (SVM), Rastgele Orman (RF), Sınıflandırma ve Regresyon Ağaçları (CART), Minimum Uzaklık (MD), Karar Ağaçları (DT) ve Gradyanla Güçlendirilmiş Ağaçlar (GTB) olmak üzere altı makine öğrenme algoritmasını kullanılmıştır. Minimum Uzaklık (MD) algoritması için en iyi doğruluğu %93, en düşük doğruluğu ise Destek Vektör Makinesi (SVM) algoritması için %74 olarak elde edilmiştir. Bu sonuçları iyileştirmek için normalleştirilmiş fark bitki örtüsü indeksi (NDVI), normalleştirilmiş fark birikim indeksi (NDBI), çıplak toprak indeksi (BSI) ve değiştirilmiş normalleştirilmiş fark su indeksi (MNDWI) gibi, farklı indeksler eklemiş ve bu indekslerin eklenmesi ile doğruluğun arttığı gösterilmiştir.

Z. Zhao vd. (2024) Pakistan'ın Mardan şehrinde Arazi Kullanım değişikliğini araştırması için, 2022'nin Sentinel-2 görüntüleri ve üç makine öğrenimi algoritması Google Earth Engine (GEE) platformunda kullanmıştır. Bu modeller Sınıflandırma ve Regresyon Ağaçları (CART), Destek Vektör Makinesi (SVM) ve Rastgele Orman (RF) modellerini içermiştir. Normalleştirilmiş Farklılık Bitki Örtüsü İndeksi (NDVI), Modifiye Edilmiş Normalleştirilmiş Farklılık Su İndeksi (MNDWI) ve Normalleştirilmiş Farklılık Yapı İndeksi gibi üç uydu indeksi, çalışma alanındaki özellikleri belirlemek için kullanılmıştır. Sentinel-2 görüntüleri için CART, SVM ve RF'nin Kappa katsayıları sırasıyla %94, %95 ve %97 ve ortalama genel doğrulukları sırasıyla %96.25, %97 ve %98.68 olarak belirlenmiştir. Bu sınıflandırma ve karşılaştırmada, RF'nin SVM ve CART'tan daha iyi performansa sahip olduğu gösterilmiştir.

Özetle tez çalışmasının bu bölümünde, mevcut bilimsel literatürdeki çalışmalar ve konuyla ilgili yapılan araştırmalar incelenmiş, tez konusunun önemini ortaya konulmuştur. Ayrıca, literatürdeki önceki çalışmaların sonuçları ve bu çalışmaların tez konusuyla olan ilişkisi değerlendirilmiştir. Bu sayede, tez çalışmasının neden önemli olduğu ve hangi konulara odaklanması gerektiği belirlenmiştir.

3. MATERYAL VE YÖNTEM


Materyal ve yöntem bölümü, bir araştırmanın nasıl yapıldığı ve hangi materyallerin kullanıldığı hakkında ayrıntılı bilgi veren bölümdür.

3.1. Materyal

Bu bölümde, çalışma alanı, kullanılan veriler, veri toplama yöntemleri, yazılımlar ve analiz araçları detaylı bir şekilde açıklanmaktadır. Bu bölüm, çalışmanın temel bileşenlerini anlamak ve çalışmanın doğruluğunu değerlendirmek için önemlidir.

3.1.1. Çalışma alanı

Araştırma alanı olarak Porsuk Havzası, Sakarya Havzası'nın bir alt havzası olup, kuzeybatı Anadolu'da 11113,66 km²'lik bir alanı kapsamaktadır. Havza, 29° 38'-31° 59' doğu boylamları ile 38° 44'-39° 99' kuzey enlemleri arasında yer almaktadır. Havza, Doğu-Batı yönünde 202 km, kuzey-güney yönünde 135 km uzunluğundadır. Şekil 3.1'de görüldüğü gibi Porsuk Havzası, Eskişehir ve Kütahya il merkezleri ile bu illere bağlı 7 ilçe merkezini, Ankara, Uşak ve Afyon il sınırları içinde kalan bazı kısımları da ihtiva etmektedir. Havzanın %60'ından fazlası dağlıktır. Porsuk Havzasının yüzey suları, Porsuk Çayı ve yan kolları tarafından toplanır ve havza içinde 436 km yol kat ettikten sonra, Sazılar mevkiinde, 660 m kotunda, Sakarya nehrine dökülür. Porsuk Havzası'nın uzun süreli yıllık ortalama yağış yüksekliğinin 451 mm olması nedeniyle, su potansiyeli azdır. Havzanın toplam yıllık su potansiyeli 481hm³tür (DSİ, 1986; DSİ, 1983).



Şekil 3.1. Porsuk Havzası'nın konumu

3.1.2. Kullanılan veriler ve yazılımlar

Kullanılan veriler ve yazılımlar bölümü, kullanılan veri kaynaklarını ve analiz için kullanılan yazılımları tanımlayan bir bölümdür. Bu bölümde, veri toplama süreci, veri kaynakları, veri analizi ve sonuçların çıkarılması için kullandığı yazılımlar ayrıntılı olarak açıklanmıştır.

3.1.2.1. Landsat uydusu

1972'den bu yana, Landsat uyduları sürekli olarak Dünya'nın kara yüzeyinin, kıyı sığlıklarının ve mercan kayalıkları uzay tabanlı görüntülerini elde etmektedir. ABD Jeoloji Araştırmaları (USGS) ve Ulusal Havacılık ve Uzay Dairesi'nin (NASA) ortak çabası olan Landsat Programı, uzaydan rutin olarak arazi görüntüleri toplamak için kuruldu. Bu programın sonucu, küresel manzaradaki doğal ve insan kaynaklı değişikliklerin uzun vadeli bir kaydıdır (Bkz. Tablo 3.1).

Tablo 3.1. Landsat uydularının sensörleri ve fırlatma tarihleri

Uydu	Tarih	Sensör
Landsat 1	July 23, 1972	MSS/RBV
Landsat 2	January 22, 1975	MSS/RBV
Landsat 3	March 5, 1978	MSS/RBV
Landsat 4	July 16, 1982	MSS/TM
Landsat 5	March 1, 1984	MSS/TM
Landsat 6	October 5, 1993	ETM
Landsat 7	April 15, 1999	ETM+
Landsat 8	February 11, 2013	OLI/TIRS

1960'ların ortalarında, ABD'nin insansız uzaktan algılama uydularıyla gezegen keşfinde elde ettiği başarılar, İçişleri Bakanlığı, NASA ve Tarım Bakanlığı'nı harekete geçirdi ve ilk sivil Dünya gözlem uydusunu geliştirme ve fırlatma çabasına yol açtı. Hedeflerine 23 Temmuz 1972'de Dünya Kaynakları Teknoloji Uydusu için Landsat 1'in fırlatılmasıyla ulaşıldı. Landsat uyduları o zamandan beri dünya çapındaki bilim ve kaynak yönetimi topluluklarına bir arşiv sağladı. 11 Şubat 2013'te başlatılan Landsat Veri Sürekliliği Misyonu (LDCM, Landsat 8 olarak yeniden adlandırıldı), Landsat arşivine eklenecek veri alımlarının sürekliliğini sağlamak için her gün Dünya yüzeyinin yüzlerce görüntüsünü yakalamakta Landsat 7'ye katılmaktadır. (Wulder et al., 2016)

Landsat 4 ve 5'teki geliştirilmiş Tematik Haritalayıcı (TM) sensörleri, spektrumun kısa dalga kızılötesi (SWIR) kısmında birkaç ek bantla tasarlandı; görünür, yakın kızılötesi (NIR) ve SWIR bantları için 30 metrelik gelişmiş uzaysal çözünürlük ve ilave olarak 120 metrelik termal IR bantı (Bkz. Tablo 3.2).

Tablo 3.2. Landsat 4-5 TM algılayıcı bantları ve özellikleri

Sensör	Bant Adı	Dalga Boyu (nm)	Çözünürlük (m)
Landsat 4-5 (TM) 1975-2013	Band 1-Blue	0.45-0.52	30
	Band 2-Green	0.52-0.61	30
	Band 3-Red	0.63-0.69	30
	Band 4-NIR	0.76-0.90	30
	Band 5-SWIR1	1.55-1.75	30
	Band 6-TIR	10.40-12.50	120
	Band 7-SWIR2	2.08-2.35	30

Landsat 7, 30 metre çözünürlüğe sahip görünür, yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantları, 60 metre termal bantı ve 15 metre pankromatik bantı olan Geliştirilmiş Tematik Haritalayıcı Plus'ı (ETM+) taşır (Bkz. Tablo 3.3).

Tablo 3.3. Landsat 7 ETM+ algılayıcı bantları ve özellikleri

Sensör	Bant Adı	Dalga Boyu (nm)	Çözünürlük (m)
Landsat 7 (ETM+) 1999'dan Günümüze	Band 1-Blue	0.45-0.52	30
	Band 2-Green	0.52-0.60	30
	Band 3-Red	0.63-0.69	30
	Band 4-NIR	0.76-0.90	30
	Band 5-SWIR1	1.55-1.75	30
	Band 6-TIR	10.40-12.50	60
	Band 7-SWIR2	2.09-2.35	30
	Band 8-Pan	0.52-0.90	15

Landsat 8, iki itici süpürge sensörü taşır: Operasyonel Arazi Görüntüleyici (OLI) ve Termal Kızılötesi Sensör (TIRS). Her iki sensör de gelişmiş sinyal-gürültü oranına sahiptir ve verileri 12 bitlik radyometrik kuantizasyonla sağlar. OLI, dokuz kısa dalga

bantında verileri 16 bitlik bir aralıkta toplar. Bu bantlar arasında 30 metre çözünürlüğe sahip sekiz spektral bant ve 15 metre çözünürlüğe sahip bir pankromatik bant bulunur. Ayrıca, iyileştirilmiş bantlar ve yeni bir aerosol bantının yanı sıra yeni bir cirrus bantının eklenmesiyle, gelişmiş radyometrik performansa sahip veri ürünleri oluşturulur. OLI veri ürünleri 16 bitlik bir aralığa sahiptir. TIRS veri ürünleri ise 30 metre çözünürlüğe ve 16 bit aralığa sahiptir. TIRS verileri, verileri 100 metre çözünürlükte iki uzun dalga termal bantta yakalar ve OLI verilerine tek bir ürün olarak kaydedilir ve onunla birlikte gönderilir (Bkz. Tablo 3.4) (Lu, 2007; Zhu et al., 2016).

Tablo 3.4. Landsat 8 OLI algılayıcı bantları ve özellikleri

Sensör	Bant Adı	Dalga Boyu (mm)	Çözünürlük (m)
Landsat 8 (OLI) 2013'ten Günümüze	Band 1-Ultra	0.43-0.45	30
	Band 2-Blue	0.45-0.51	30
	Band 3-Green	0.53-0.59	30
	Band 4-Red	0.64-0.67	30
	Band 5-NIR	0.85-0.88	30
	Band 6-SWIR1	1.57-1.65	30
	Band 7-SWIR2	2.11-2.29	30
	Band 8-Pan	0.50-0.68	15
	Band 9-Circus	1.36-1.38	30
	Band 10-TIR1	10.60-11.19	100
	Band 11-TIR2	11.50-12.51	100

Çalışmada kullanılan uydu görüntüleri şunlardır:


- Landsat-5 TM görüntüleri,
- Landsat-7 ETM+ görüntüleri,
- Landsat-8 OLI/TIRS görüntüleri

Landsat-7 Collection 2 seviye 2 uydusuna ait ETM+ algılayıcısı görüntülerinin tarihleri şunlardır: 04 Temmuz 2000 ve 27 Temmuz 2000 (Bkz. Şekil 3.2).


Landsat-5 Collection 2 seviye 2 uydusuna ait TM algılayıcısı görüntülerinin tarihleri şunlardır: 22 Ağustos 2009 ve 29 Ağustos 2009 (Bkz. Şekil 3.3).

Landsat-8 Collection 2 seviye 2 uydusuna ait OLI/TIRS algılayıcısı görüntülerinin tarihleri şunlardır: 04 Ağustos 2020 ve 27 Ağustos 2020 (Bkz. Şekil 3.4).


Görüntülenme tarihlerinde algılayıcılar normal şekilde çalışmakta ve görüntüde herhangi bir anormalliğe rastlanmamaktadır ve tüm bantlarda görüntü kalitesi, algılayıcı tarafından algılanabilecek en üst düzeydedir. Ayrıca Görüntülerin çekildikleri tarihler, mümkün olduğunca yakın tarihler olarak seçilmiştir. 2000 tarihli görüntüde bulut oranı sıfırdır, 2009 tarihli görüntüdeki bulut oranı neredeyse sıfıra yakındır ve 2020 tarihli görüntüde bulut oranı da sıfıra yakındır. Aldığımız tüm uydu görüntülerinin izlediği yol veya path 179 ve 178, görüntü sırası veya row ise 32 ve 33'tür.



Şekil 3.2. 2000 yılına ait Landsat 7 uydu görüntüleri



Şekil 3.3. 2009 yılına ait Landsat 5 uydu görüntüleri



Şekil 3.4. 2020 yılına ait Landsat 8 uydu görüntüleri

3.1.2.2. Spektral indeksler

Uzaktan algılama, elektromanyetik spektrumun farklı bantlarından gelen bilgileri kullanarak çeşitli nesne ve yüzeyler hakkında bilgi toplama yöntemidir. Spektral indeksler, bu elektromanyetik spektrumun belirli bantlar arasındaki ilişkileri ifade eden matematiksel formüllerdir. Bu indeksler, belirli özellikleri vurgulamak veya belirli nesneleri veya yüzey örtülerini tanımlamak için kullanılır. Bu çalışmada kullanılan spektral indeksler şunlardır:

NDVI: Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), bitkilerin sağlık durumunu belirlemek için kullanılan bir indekstir. Uydu görüntülerinde yakalanan bitki örtüsünün yeşilliğini ve yoğunluğunu ölçer. Sağlıklı bitki örtüsü, görünür kırmızı ve yakın kızılötesi olmak üzere iki bant arasındaki farkı hesaplamak için kullanılabilen çok karakteristik bir spektral yansıtma eğrisine sahiptir. NDVI, -1 ile 1 arasında değişen bir sayı olarak ifade edilen farktır (Gessesse & Melesse, 2019).

NDVI, orman alanlarının izlenmesi ve kuraklık durumlarının belirlenmesi gibi çeşitli pratik uygulamalarda kullanılan en yaygın uzaktan algılama indekslerinden biridir. NDVI, farklı aydınlatma koşullarını, yüzey eğimini ve görüş açısını dikkate alarak bitki örtüsünü izlemek için özellikle yararlıdır. NDVI denklemi $(NIR - Kırmızı) / (NIR + Kırmızı)$ şeklindedir (Viana et al., 2019).

NDWI: Normalleştirilmiş Fark Su İndeksi (NDWI), yaprakların su içeriğini tahmin etmek için kullanılan, uzaktan algılamadan türetilen bir indekstir. Su kütlesindeki su içeriği değişikliklerini izlemek için kullanılır ve bir su kütlesinin diğer yüzey öğelerine

göre belirginleşmesini sağlar. Ayrıca, uydu görüntülerindeki açık su alanlarını vurgulamak için kullanılır. NDWI, yakın kızılötesi (NIR) ve yeşil bantlardan elde edilen veriler kullanılarak hesaplanır. Yaprakların su içeriğindeki değişikliklere hassasiyeti nedeniyle NDWI indeksi, bitki su içeriği ile güçlü bir ilişkiye sahiptir. Bu özelliği, NDWI'yi bitki su stresi için etkili bir gösterge yapar. NDWI denklemi (Yeşil - NIR) / (Yeşil + NIR) şeklindedir (Teng et al., 2021).

NDBI: Normalleştirilmiş Fark Yapı İndeksi (NDBI), kısa dalga kızılötesi (SWIR) bantında tipik olarak daha yüksek yansımaların olduğu kentsel alanları vurgulamak için uzaktan algılamada kullanılan bir indekstir. NDBI, uydu görüntülerinde yerleşim alanının toplam alana oran haritasıdır. NIR ve SWIR bantlarını kullanarak üretilen NDBI, yerleşim alanlarını vurgulamak için tasarlanmıştır. Ayrıca, atmosferik etkilerin yanı sıra arazi aydınlatma farklılıklarının etkilerini azaltmak için oran tabanlı bir yaklaşımı benimser. NDBI denklemi (SWIR1 - NIR) / (SWIR1 + NIR) şeklindedir (Guha et al., 2021).

UI, BUI, BRBA, BAEI ve NBI gibi diğer kentsel indeksler, uzaktan algılamadan elde edilen verilerle kentsel alanların belirlenmesi için kullanılan spektral indekslerdir. (Kaya & Dervisoglu, 2023). Bu indekslerin formülleri Tablo 3.5' te açıklanmıştır.

Tablo 3.5. İndekslerin formülleri

İndeks ad	İndeks ID	Formül	Kaynakça
Urban Index	UI	$\left(\frac{SWIR2 - NIR}{SWIR2 + NIR} + 1.0 \right) \times 100$	(Kawamura et al., 1997)
Built-up Index	BUI	$NDBI - NDVI$	(He et al., 2010)
New Built-up Index	NBI	$\frac{SWIR1 * RED}{NIR}$	(Jieli et al., 2010)
Band Ratio for the Built-up Area	BRBA	$\frac{RED}{SWIR1}$	(Waqar et al., 2012)
Built-up area Extraction Index	BAEI	$\frac{RED + 0.3}{GREEN + SWIR1}$	(Bouzekri et al., 2015)

İstatistiksel parametreler, spektral indekslerin belirli bir uygulama alanında ne kadar etkili olduğunu anlamak için kullanılabilir. Bu parametreler, spektral indekslerin veri dağılımını ve merkezi eğilimini açıklamaya yardımcı olur. Önemli istatistiksel parametreler arasında ortalama, standart sapma, medyan, minimum ve maksimum değerleri yer alır.

Tablo 3.6. *Spektral indekslerin istatistiksel parametreleri*

	NDVI	NDBI	NDWI	NBI	UI	BUI	BAEI	BRBA
Count	1.56E+07	1.56E+07	1.56E+07	1.56E+07	1.56E+07	1.56E+07	1.56E+07	1.56E+07
Mean	3.49E-01	-8.87E-03	-4.28E-01	1.69E-01	-1.89E-01	-3.58E-01	1.21E+00	4.88E-01
Std	2.01E-01	1.59E-01	1.53E-01	1.01E-01	1.98E-01	3.48E-01	5.47E-01	1.31E+00
Min	-1.00E+00	-9.91E-01	-9.86E-01	-1.11E+01	-9.80E-01	-1.65E+00	-2.03E+02	-5.78E+02
25%	1.98E-01	-5.67E-02	-5.26E-01	8.12E-02	-2.69E-01	-5.25E-01	9.51E-01	3.91E-01
50%	2.72E-01	4.94E-02	-3.90E-01	1.75E-01	-1.22E-01	-2.08E-01	1.06E+00	4.95E-01
75%	4.73E-01	9.39E-02	-3.27E-01	2.44E-01	-5.18E-02	-1.10E-01	1.28E+00	5.70E-01
Max	9.79E-01	9.99E-01	1.00E+00	4.63E+01	9.99E-01	2.00E+00	9.01E+01	3.13E+03

Tablo 3.6'dan, Porsuk Havzası'nı oluşturan piksel sayısının $1.56 \cdot 10^7$ olduğu gösterilmiştir. NDVI için en yüksek (Max) yansımaya değeri 0.979 ve en düşük (Min) yansımaya değeri -1 olarak hesaplanmıştır. Ortalama yansımaya değeri 0.349 ve standart sapma değeri 0.201 olarak hesaplanmıştır.

NDBI için, en yüksek yansımaya değeri 0.999 ve en düşük yansımaya değeri -0.991 olarak hesaplanmıştır. Ortalama yansımaya $-8.87 \cdot 10^{-3}$ ve standart sapma değeri 0.159 olarak hesaplanmıştır.

NDWI için, en yüksek yansımaya değeri 1 ve en düşük yansımaya değeri -0.986 olarak hesaplanmıştır. Ortalama yansımaya değeri -0.428 ve standart sapma değeri 0.153 olarak hesaplanmıştır.

NBI için, en yüksek yansımaya değeri 46.3 ve en düşük yansımaya değeri -11.1 olarak hesaplanmıştır. Ortalama yansımaya değeri 0.169 ve standart sapma değeri 0.101 olarak hesaplanmıştır.

3.1.2.3. İndeksler arasındaki korelasyon


Değişkenler arasındaki karşılıklı ilişkinin derecesini ölçmek için Pearson'un momentler çarpımı korelasyon katsayısı (r) yaygın olarak kullanılır. Örneğin, uzaktan

algılanan verinin iki bantı (k ve l) arasındaki korelasyon (r_{kl}), bantların kovaryanslarının (cov_{kl}) standart sapmalarının ($s_k s_l$) çarpımına oranıdır (W Yue J Xu & Xu, 2007).

$$r_{kl} = \frac{cov_{kl}}{s_k s_l} \quad (3.1)$$

Korelasyon katsayısı bir oran olduğundan birimsiz bir sayıdır. Kovaryans, değişkenlerinin standart sapmasının çarpımına eşit olabilir ancak bu çarpımı aşamaz; dolayısıyla korelasyon +1 ile -1 arasında değişir.

Korelasyon katsayısının +1 olması, iki banttaki parlaklık değerleri arasında pozitif, mükemmel bir ilişkiyi gösterir. Bu durumda, bir bantın piksellerinin değeri arttıkça, diğer bantın değerleri de sistematik olarak artar. Tersine, -1 korelasyon katsayısı, iki bantın tamamen ters ilişkili olduğunu gösterir. Bu durumda, bir banttaki parlaklık değerleri arttıkça, diğer banttaki karşılık gelen piksellerin değeri sistematik olarak azalır. Sıfır korelasyon katsayısı, uzaktan sensör verilerinin iki bantı arasında doğrusal bir ilişki olmadığını gösterir (W Yue J Xu & Xu, 2007).



Şekil 3.5. İndeksler arasındaki korelasyon


Şekil 3.5'te görüldüğü gibi, NBI ve NDBI arasında 0.74'lük pozitif bir ilişki görülebilir. Bu, yüksek bir korelasyona (güvenilir bir ilişki) sahip olduklarını gösterir. Her bir NBI yansıma değerinin ardından bir NDBI yansıma değeri gelir. Ayrıca, eğer NBI'nin yansıma değeri düşükse, NDBI'nin yansıma değeri de düşük olacaktır. Bu durum, NBI ve NDBI'nin benzer yapıya sahip doğrusal spektral indeksler olduğunu gösterir. Tespit edilen nesnelerin yapay yüzeyler olarak benzerliği, UI ve NDBI spektral indeksleri arasındaki pozitif ilişkiyi açıklar. NDWI ve NDBI arasında 0.8'lik pozitif bir ilişki ve NDWI ve NBI spektral indeksleri arasında 0.81'lik pozitif bir ilişki tespit edilmiştir. Bu durum, bu indeksler arasında çok yüksek pozitif korelasyon olduğunu göstermektedir. Ayrıca NDVI ile NDWI arasındaki ilişkinin -0.97'lik negatif bir korelasyon değerine sahip olduğu gözlemlenmiştir. Bu durum, NDVI'nin yansıma değeri arttığında, NDWI'nin yansıma değerinin azalacağı anlamına gelir. Bu durumda, bir alanın bitki örtüsü olduğunda su alanı bulunmadığını gösterir. Dolayısıyla NDVI ile NDWI arasındaki korelasyon çok yüksek negatif bir korelasyon olarak değerlendirilebilir. NDVI ve NDBI spektral indeksleri arasında -0.88'lik negatif bir ilişki ve NDVI ile NBI spektral indeksleri arasında -0.86'lik negatif bir ilişki tespit edilmiştir. Bu durum, bu indeksler arasında çok yüksek negatif korelasyon olduğunu göstermektedir. Çalışmada indekslerin arasındaki korelasyona göre materyal olarak kullanılan, NDVI, NDWI, NDBI ve NBI indeksleri seçilmiş ve iki farklı veri seti oluşturulmuştur:

- Veri seti 1: Landsat multispektral bantlar (B1, B2, B3, B4, B5, B6, B7)
- Veri seti 2: Landsat multispektral bantlar (B1, B2, B3, B4, B5, B6, B7), Landsat termal bantlar, NDVI , NDBI , NBI , NDWI

3.1.2.4. Google Earth Engine

Google Earth Engine, gezegen ölçeğinde coğrafi mekansal analiz için bulut tabanlı bir platformdur. Google Earth Engine, onu coğrafi mekansal analiz için güçlü bir araç yapan çeşitli avantajlara sahiptir. İlk olarak, kullanıcılara, Dünya yüzeyindeki değişiklikleri tespit etmek, eğilimleri haritalamak ve farklılıkları ölçmek için kullanılabilen uydu görüntüleri dahil olmak üzere 900'den fazla coğrafi mekansal veri setine erişim sağlar. İkinci olarak, Google Earth Engine, daha hızlı analizler sağlayan ve kullanıcıların kendi altyapılarına sahip olma ihtiyacını ortadan kaldıran bulut işlemeyi kullanır. Üçüncüsü, Google Earth Engine'in çok terabaytlık bir uydu görüntüleri ve coğrafi mekansal veri kümeleri kataloğu vardır, bu da onu geniş ölçekte çalışmak için

güçlü bir araç haline getirir. Dördüncüsü, Google Earth Engine, kullanıcıların kendi kişiselleştirilmiş sitelerini ve başkalarıyla paylaşılabilen analitik araçlarını geliştirmelerine olanak tanır, bu da iş birliğini ve veri paylaşımını teşvik eder. Ancak, Google Earth Engine'in JavaScript ve Python kodlama becerileri gerektirdiğini ve ücretsiz sürümünün bazı işleme ve depolama sınırları olduğunu belirtmek önemlidir. Ayrıca, görüntülerin ve sonuçların dışa aktarılmasının zor olabileceğine dikkat etmek gerekir (Gorelick et al., 2017). Yapılan çalışmada bu platform kullanılarak değişim analizi gerçekleştirilmiştir (Bkz. Şekil 3.6).



Şekil 3.6. Google Earth Engin platformu

3.2. Yöntem

Bu bölüm iki kısımdan oluşmaktadır; bunlar genel olarak değişim analizinde kullanılan yöntemler ve tez çalışmasında değişimin analiz edilmesi ve sonuçların elde edilmesi için kullanılan yöntemlerdir.

3.2.1. Değişim analizi teknikleri

Değişim analizi için genellikle üç kategoriye ayrılan yöntemler kullanılmaktadır; bunlar cebirsel yöntemler, dönüşüme dayalı yöntemler ve sınıflandırmaya dayalı yöntemlerdir.

3.2.1.1. Cebirsel yöntemler

Cebir kategorisi, görüntü farklılaştırma, görüntü regresyon, görüntü rasyonlama, bitki indeksi farklılaştırma ve değişim vektörü analizini (CVA) içerir. Bu algoritmaların ortak bir özelliği vardır, yani değişen alanları belirlemek için eşiklerin seçilmesidir. Bu

yöntemler (CVA hariç) nispeten basit, anlaşılır, uygulanması ve yorumlanması kolaydır, ancak bunlar tam değişim bilgisi matrisleri sağlayamazlar. CVA, görüntü farklılaştırmanın kavramsal bir uzantısıdır. Bu yaklaşım, tanımlanan eşiklerden daha büyük tüm değişiklikleri tespit edebilir ve ayrıntılı değişiklik bilgileri sağlayabilir.

Cebir kategorisinin bir dezavantajı, değiştirilen alanları belirlemek için uygun eşiklerin seçilmesindeki zorluktur. Bu kategoride, değişiklik saptama sonuçları için iki husus kritiktir: uygun görüntü bantları veya bitki örtüsü indekslerinin seçilmesi ve değiştirilen alanları belirlemek için uygun eşiklerin seçilmesidir.

Cebir tabanlı değişim tespit kategorisinde, pratikte en sık kullanılan değişim tespit yöntemi görüntü farkıdır. Görünür kırmızı bantın görüntü farkının yarı kurak ve kurak ortamlarda değişiklik tespiti için uygun olduğu gösterilmiştir, ancak bunun nemli tropikal bölgeler gibi diğer ortamlarda doğru olup olmadığı açık değildir (Lu et al., 2004).

- **Görüntü farklılaştırma:** Bu basit yöntem yaygın olarak kullanılmaktadır ve farklı zamanlarda elde edilen kayıtlı görüntülerin piksel piksel ve bant bant çıkarılmasından oluşur. Bu yöntem basit ve anlaşılır, sonuçları yorumlaması kolaydır, ancak ayrıntılı bir değişim matrisi sağlayamaz ve eşiklerin seçimini gerektirir (Lu et al., 2004).

- **Görüntü regresyonu:** İki zamanlı görüntüler arasında ilişkiler kurulur, ardından bir regresyon işlevi kullanılarak ikinci tarihli görüntünün piksel değerleri tahmin edilir. Bu tahmin, ilk tarihli görüntüden regresyona uğratılmış görüntü olarak çıkarılır.

Bu yaklaşım, aynı alanın iki farklı zamandaki piksel değerleri arasında doğrusal bir ilişki olduğunu varsayar. Bu, piksellerin çoğunun iki tarih arasında değişikliklerle karşılaşmadığı anlamına gelir. Her bir spektral bantın piksel değerleri arasındaki ilişkiyi iki tarihte en iyi tanımlayan bir regresyon fonksiyonu geliştirilir. Regresyon artıklarının değişim alanlarını temsil ettiği kabul edilir. Bu yöntem, çok tarihli görüntüler arasındaki radyometrik heterojenliğin (atmosfer, güneş açısı, sensör kalibrasyonu) etkisini azaltma avantajına sahiptir. Ancak zorlu adımlar, uygun bir regresyon fonksiyonu seçmek ve değişiklik ve değişiklik olmayan alanlar arasındaki eşikleri tanımlamaktır (Théau, 2017).

- **Görüntü oranlama:** Güneş açısı, gölge ve topografyanın etkilerini azaltır. Farklı zamanlarda elde edilen kayıtlı görüntülerin piksel piksel ve bant bant oranıdır. Değişiklikler, 1'den büyük veya küçük piksel değerleriyle temsil edilir. Değişiklik olmayan piksellerin değeri 1 olacaktır. Uygulamada, görüntü farklılaştırmada olduğu gibi aynı nedenlerle, bu tekniğin zorluğu değişiklik ve değişiklik yok arasında eşik değerleri

seçmektir. Bu teknik genellikle eleştirilir çünkü sonuçların normal olmayan dağılımı, elde edilen piksellerin standart sapması kullanılarak eşik seçiminin geçerliliğini sınırlar (Lu et al., 2004).

- **Vejetasyon indeksi farkı:** Bitki örtüsü indeksini ayrı olarak üretir, ardından ikinci tarihteki bitki örtüsü indeksini birinci tarihteki bitki örtüsü indeksinden çıkarır. Bu yöntem, farklı özelliklerin spektral tepkisindeki farklılıkları vurgular ve topografik etkilerin ve aydınlatmanın etkilerini azaltır, ancak rastgele gürültüyü veya tutarlılık gürültüsünü artırır (Guerra et al., 1998).

- **Değişim vektör analizi (CVA):** Bu yaklaşım, bir spektral uzayda değişimin mekansal temsiline dayanır. Bir piksel iki tarih arasında bir değişikliğe uğradığında, n-boyutlu spektral uzaydaki konumunun değişmesi beklenir. Bu değişim, Değişim Tespiti olarak tanımlanan bir vektör ile temsil edilir, Değişim vektörü prosedürünün örneği ve prensibi, değişimin doğası hakkında bilgi sağlayan yön ve değişimin seviyesi hakkında bilgi sağlayan büyüklük olmak üzere iki faktör tarafından temsil edilir.

Bu yaklaşım, herhangi bir sayıda spektral bantı aynı anda işleme avantajına sahiptir. Ayrıca, değişiklik hakkında ayrıntılı bilgi sağlar. Ancak, bu yöntemin zorlu adımları, büyüklük eşiklerini tanımlamak, değişiklik ve değişiklik olmaması arasında ayırım yapmak ve vektör yönünü değişimin doğası ile ilişkilendirmektir. Bu yaklaşım genellikle yöntemler kullanılarak dönüştürülmüş veriler üzerinde gerçekleştirilir ve iki çıktı üretir: (1) spektral değişim vektörü, birinci tarihten ikinci tarihe kadar olan değişimin yönünü ve büyüklüğünü tanımlar; ve (2) piksel başına toplam değişim büyüklüğü, n-boyutlu değişim uzayı yoluyla uç noktalar arasındaki Öklid mesafesinin belirlenmesiyle hesaplanır (Théau, 2017).

3.2.1.2. Dönüşüme dayalı yöntemler

Dönüşüm kategorisi, PCA, TC ve Gramm–Schmidt (GS) dönüşümlerini içerir. Bu yöntemlerin bir avantajı, bantlar arasındaki veri fazlalığını azaltması ve türetilmiş bileşenlerde farklı bilgileri vurgulamasıdır. Ancak, ayrıntılı değişiklik matrisleri sağlayamazlar ve değişen alanları belirlemek için eşiklerin seçilmesini gerektirirler. Diğer bir dezavantaj, dönüştürülen görüntüler üzerindeki değişiklik bilgilerinin yorumlanması ve etiketlenmesindeki zorluktur.

Dönüşüm kategorisinde, PCA ve TC, değişiklik olmayan bilgileri tespit etmek için en sık kullanılan yaklaşımlardır. TC yöntemi, birçok değişiklik tespit uygulamasında

faydalı görünmektedir. TC dönüşümünün PCA'ya göre bir avantajı, onun dönüşüm katsayılarının görüntü sahnelerinden bağımsız olması, PCA'nın ise görüntü sahnelerine bağlı olmasıdır. GS yöntemi, PCA ve TC dönüşümlerine kıyasla göreceli karmaşıklıkları nedeniyle pratikte nispeten daha az kullanılır. Ayrıca GS yöntemi, ticari uzaktan algılama görüntü işleme yazılımlarının çoğunda mevcut değildir (Lu et al., 2004).

- Temel bileşen analizi (PCA): Çok zamanlı verilerin yüksek oranda ilişkili olduğunu ve yeni bileşenlerde değişiklik bilgilerinin vurgulanabileceğini varsayar. Değişiklik tespiti için PCA'yı uygulamanın iki yolu şunlardır: (1) iki veya daha fazla görüntü tarihini tek bir dosyaya koymak, ardından PCA gerçekleştirin ve değişiklik bilgileri için küçük bileşen görüntülerini analiz etmektir ve (2) PCA'yı ayrı olarak gerçekleştirmek, ardından ikinci tarihli PCA görüntüsünü karşılık gelenden çıkarmaktır.

Bu yöntem, bantlar arasındaki veri fazlalığını azaltır ve türetilmiş bileşenlerdeki farklı bilgileri vurgular, ancak PCA sahneye bağlıdır, bu nedenle farklı tarihler arasındaki değişiklik algılama sonuçlarının yorumlanması ve etiketlenmesi genellikle zordur. Bu zor adımlar, temel bileşenlerden değişiklikleri etiketlemek ve değişiklik ile değişmeyen alanlar arasındaki eşikleri seçmektir. Çalışma alanı hakkında iyi bir bilgi gereklidir. Tam bir değişiklik sınıf bilgisi matrisi sağlayamaz ve değiştirilen alanları tanımlamak için eşiklerin belirlenmesini gerektirir (Lu et al., 2004).

- Tasselled cap (TC): Bu yöntemin prensibi PCA'ya benzer. PCA'dan tek farkı, PCA'nın görüntü sahnesine bağlı olması ve TC dönüşümünün sahneden bağımsız olmasıdır. Değişiklik tespiti, üç bileşene dayalı olarak uygulanır: parlaklık, yeşillik ve ıslaklık.

Bu yöntem, bantlar arasındaki veri fazlalığını azaltır ve türetilmiş bileşenlerdeki farklı bilgileri vurgular, ancak yorumlanması ve değişiklik bilgilerini etiketlemesi zordur, tam bir değişiklik matrisi sağlayamaz; değişen alanları belirlemek için eşiklerin belirlenmesini gerektirir ve görüntünün her tarihi için doğru atmosferik kalibrasyon gereklidir. PCA'dan farklı olarak, değişiklik tespiti için Tasseled-Cap dönüşümü, çok tarihli görüntülerin doğru atmosferik kalibrasyonunu gerektirir (Lu et al., 2004).

- Gramm–schmidt (GS): GS yöntemi, doğrudan iki zamanlı görüntülerden alınan spektral vektörleri ortogonal hale getirir. Orijinal TC yönteminde olduğu gibi, parlaklık, yeşillik ve ıslaklık için çok zamanlı analoglar oluşturur ve üç kararlı bileşen ve bir değişim bileşeni üretir.

Dönüştürülen bileşenlerin sahne özellikleriyle ilişkilendirilmesi, diğer değişiklik algılama teknikleri kullanılarak erişilemeyecek bilgilerin çıkarılmasına olanak tanır. Ancak, belirli bir değişiklik türüyle ilgili birden fazla tek bileşen çıkarmak zordur. GS süreci, incelenen değişiklik tipine özgü çok-tarihli görüntüden spektral vektörlerin seçilmesine dayanır (Lu et al., 2004).

3.2.1.3. Sınıflandırmaya dayalı yöntemler

Arazi örtüsü veya arazi kullanım haritaları üretmek için geliştirilmiş ve yaygın olarak kullanılan çeşitli sınıflandırma teknikleri vardır. Uydu görüntüsü sınıflandırma yöntemleri genel olarak iki kategoride sınıflandırılabilir: 1) Kontrolsüz 2) Kontrollü. Her iki yöntemin de kendi avantajları ve dezavantajları vardır (Abburu & Golla, 2015).

- **Kontrolsüz sınıflandırma:** Kontrolsüz sınıflandırma tekniği, uydu görüntüsü piksellerini etiketlenmemiş sınıflar veya kümeler halinde gruplandırmak için kümeleme mekanizmalarını kullanır. Analist, oluşturulacak sınıfların veya kümelerin sayısını ve hangi bantların kullanılacağını belirler. Bu bilgilere dayanarak, görüntü sınıflandırma algoritması sınıflar üretir. İyi sınıflandırılmış bir uydu görüntüsü üretmek için analist, her küme etiketini bir arazi örtüsü sınıfını manuel olarak tanımlar. Çoğu zaman birden fazla kümenin tek bir arazi örtüsü sınıfını temsil etmesi söz konusudur. Analist, kümeleri tek bir arazi örtüsü sınıfında birleştirir. Kontrolsüz sınıflandırma tekniği, eğitim örnek sitelerinin olmadığı durumlarda yaygın olarak kullanılır. Kontrolsüz sınıflandırma için en sık kullanılan iki kümeleme yöntemi vardır, bunlar K-means ve ISODATA Tekniğidir (Salah, 2017).

- **Kontrollü sınıflandırma:** Kontrollü sınıflandırma, analistin eğitim örneği adı verilen her bir arazi örtüsü sınıfı için küçük temsili örnekler tanımladığı bir yöntemdir. Kontrollü sınıflandırmada, analist uydu görüntüsünün kapsadığı alana ve arazi örtüsü sınıflarının spektral özelliklerine aşina olmalıdır. Analiz sırasında, bu eğitim örnekleri kullanılarak uydu görüntüsünün pikselleri sınıflandırılır. Pikseller, sahip oldukları spektral özelliklere göre belirli arazi örtüsü sınıflarına atanır. Ancak, bu süreçte doğru sonuçlar elde etmek için dikkatli bir şekilde seçilmiş eğitim örneklerinin yanı sıra uydu görüntüsünün kalitesi, çözünürlüğü ve sahadaki koşullar da göz önünde bulundurulmalıdır.

Sınıflandırma sonuçlarının doğruluğu büyük ölçüde eğitim için alınan örneklemelere bağlıdır. Görüntü sınıflandırma algoritmaları, görüntünün tamamındaki arazi örtüsü sınıflarını belirlemek için eğitim örneklerini kullanır. Bunlar arasında Parallelepiped (PP), Yapay Sinir Ağları (ANN), Sınıflandırma Ağaçları (CTs), Rastgele

Orman (RF), Minimum Mesafe (MD), Mahalanobis Mesafesi (MHD), Sınıflandırma ve Regresyon Ağaçları (CART), Maksimum Olabilirlik (MXL), Gradyanla Güçlendirilmiş Ağaçlar, K-Nearest Neighbor (KNN) ve Destek Vektör Makineleri (SVMs) bulunmaktadır (Jawak et al., 2015).

3.2.2. Çalışmada kullanılan değişim analizi teknikleri

Kontrollü sınıflandırma yöntemlerin arasından, çalışmada kullanılan sınıflandırma yöntemleri aşağıda açıklanmıştır:

3.2.2.1. Destek Vektör Makinesi (SVM)

SVM'ler, makine öğrenmesi alanındaki en yeni gelişmelerden biri olup istatistiksel öğrenme teorisi ilkelerine dayanmaktadır.

Mountrakis et al. (2011), SVM algoritmasını kullanarak 100'den fazla makaleden elde edilen sonuçları özetlemiştir. Sonuç olarak, SVM'lerin sınıflandırma doğruluğu açısından diğer birçok görüntü sınıflandırma algoritmasından üstün olduğu kanıtlanmıştır. SVM'ler, iki sınıf arasındaki ayırıcı hiperdüzlemi en iyi şekilde belirlemek için çok boyutlu özellik alanındaki eğitim verilerine dayanır. Bu nedenle, SVM'ler, sınıflandırma doğruluğunu artırmak için iki sınıfın özelliklerini en iyi şekilde betimler. SVM'ler, iki sınıf arasındaki ayırıcı hiperdüzlemi en iyi şekilde belirlemek için çok boyutlu özellik alanındaki eğitim verilerine dayanır. Bu nedenle, SVM'ler, sınıflandırma doğruluğunu artırmak için iki sınıfın özelliklerini en iyi şekilde betimler (Shih et al., 2019).

Polinom çekirdeği, doğrusal çekirdek ve radyal tabanlı çekirdek (RBF) gibi çeşitli çekirdek işlevleri mevcuttur. Çekirdek seçimi de sınıflandırmanın sonuçlarını etkiler (Foody & Mathur, 2004). Uzaktan algılamada, Polinom ve radyal tabanlı fonksiyon (RBF) çekirdekleri en yaygın olarak kullanılan SVM çekirdeklerindendir (Maxwell et al., 2018).

Arazi kullanımı sınıflandırması için Polinom ve RBF çekirdekleri en popüler tekniktir ve diğer geleneksel yöntemlere kıyasla daha iyi doğruluk sağlar. SVM yöntemi, veri setlerini birkaç sınıfa ayırabilen en uygun hiperdüzlemi bulmayı amaçlar. SVM'nin amacı, veri setlerini en iyi şekilde ayıran hiperdüzlemi bulmaktır (Srivastava et al., 2012).

SVM tekniğinin en önemli kısmı kullanılan çekirdek türüdür. SVM'nin işlevselliği temel olarak çekirdek boyutuna bağlıdır ve düzgün bir yüzeyin benzerliği, daha önemli olan çekirdek yoğunluğuna bağlıdır. Simüle edilmiş ve gerçek dünya hiperspektral uydu

verileri için, destek vektörlerini kullanan genetik olarak optimize edilmiş SVM en iyi performansı gösterir (Mathur & Foody, 2008).

Ayrıca, doğru bir şekilde hiperdüzlemleri oluşturmak ve sınıflandırma hatalarını en aza indirmek için SVM algoritmasının uygun bir çekirdek fonksiyonuna ihtiyacı vardır. Çekirdek fonksiyonu, veri noktalarını yüksek boyutlu uzayda temsil etmek için kullanılır ve bu uzayda doğrusal olarak ayrılamayan verileri doğrusal olarak ayrılabilir hale getirir. Doğru çekirdek fonksiyonunun seçilmesi, SVM'nin sınıflandırma performansını etkiler ve belirli bir uygulama bağlamında en iyi sonuçları elde etmek için önemlidir. (Awad & Khanna, 2015). Bu çalışmada kullanılan SVM yönteminin parametreleri, Tablo 3.7'de gösterilmektedir.

Tablo 3.7. SVM yönteminin parametreleri

Parametreler	Değer	Açıklama
svmType	C_SVC	
kernelType	POLY	
degree	3	Polinom derecesi. POLY çekirdekleri için geçerlidir.
gamma	0.1	Çekirdek fonksiyonundaki gama değeri. Unsurların sayısının tersi varsayılan olarak alınır. POLY, RBF ve SIGMOID çekirdek'leri için geçerlidir.
coef0	0.5	Çekirdek fonksiyonundaki coef0 değeri. Varsayılan değerler 0'dır. POLY ve SIGMOID çekirdek'leri için geçerlidir.
cost	15	cost (C) parametresi. Varsayılanlar 1'dir. Yalnızca C-SVC, epsilon-SVR ve nu-SVR için geçerlidir.

3.2.2.2. Sınıflandırma ve Regresyon Ağaçları (CART)

CART, Breiman, Friedman, Olshen ve Stone (1984) tarafından geliştirilen ve hiyerarşik karar ağaçları çerçevesine dayalı olarak çalışan en basit ikili sınıflandırıcılardan biridir. Bu tür yapıların temel avantajı, sınıflandırma kararlarının, çok katmanlı sinir ağlarına kıyasla girdi-çıkı ilişkilerinin kolayca anlaşılıp yorumlanabildiği bir beyaz kutu sistemi gibi ele alınabilmesidir (Mather & Tso, 2016).

CART algoritmalarının girdisi ve çıktısı, her düğümün iki dala bölündüğü bir dizi düğümle bağlanır. Sınıflandırma ağaçları durumunda sonunda sınıf etiketlerini temsil eden yaprak düğümlere, regresyon ağaçları durumunda ise sürekli değişkenlere yol açar. Düğümlerin tekrarlanan bölünmesi, bir eşik kriterine ulaşana kadar devam eder. CART,

her düğümde en iyi ayrımı sağlayacak girdi özelliklerine karar vermek için Gini Safsızlık Endeksini kullanır (Mather & Tso, 2016).

CART, özellikle eğitim verilerine daha iyi uyduğunda ağaca fazla sığdırma eğilimindedir. Bu, ağacı budayarak eğitim dışı girdi verilerine karşı daha sağlam hale getirilir. CART, budama için, etkileri belirli bir eşiğin ötesine geçmeyen dalları azaltan bir çapraz doğrulama tekniği kullanır. Bu çapraz doğrulama tekniği, ağacın her bir dalının performansını değerlendirir ve belirli bir eşiğin ötesinde performansı etkilemeyen dalları keser. Bu, modelin genelleme yeteneğini artırarak aşırı uydurmayı önler. Budama işlemi, ağacın karmaşıklığını azaltırken modelin performansını optimize etmeyi amaçlar. (Lawrence & Wright, 2001). Bu, eğitim verilerinin sınıflandırılması için doğruluğun azalmasına ve belirli bilgilerin kaybolmasına neden olabilirken, diğer yandan bilinmeyen veriler için doğruluğun artmasına neden olabilir (Pal & Mather, 2003).

CART gibi ağaç tabanlı sınıflandırıcılar, uzaktan algılama alanındaki çeşitli çalışmalarda yaygın olarak kullanılmaktadır, örneğin MODIS küresel arazi örtüsü verileri, sağlamlığı ve basitliği nedeniyle CART kullanılarak geliştirilmiştir (Friedl et al., 2002).

Lawrence & Wright (2001) çalışmaları aracılığıyla, CART'ın sınıflandırma için yararlı olan bu girdi ve yardımcı verileri otomatik olarak seçme konusunda büyük bir avantaja sahip olduğunu göstermektedir. Ek olarak CART, her yaprak düğümünde yanlış sınıflandırma olasılığı sağlayarak değerlendirme kalitesini değerlendirmede yardımcı olur. CART daha düşük boyutlu veriler için, Sinir Ağlarından daha hızlı performans gösterir ve aynı zamanda karşılaştırılabilir sonuçlar sunar (Pal & Mather, 2003).

Öte yandan, CART her sınıf için seçilen örneklem büyüklüğüne oldukça duyarlıdır. Yüksek boyutlu verilerde, karmaşık ağaç yapılarına yol açarak CART'ın performansını düşürebilir. Bu durum, modelin aşırı uyum ve genelleme yapma yeteneğini etkileyebilir, bu nedenle uygun örneklem büyüklüğünün seçimi önemlidir (Pal & Mather, 2003). Bu çalışmada kullanılan Cart yönteminin parametreleri, Tablo 3.8'de gösterilmektedir.

Tablo 3.8. CART yönteminin parametreleri

Parametreler	Değer	Açıklama
maxNodes	100	Her ağaçtaki maksimum yaprak düğümü sayısı.
minLeafPopulation	1	Eğitim seti en az bu kadar nokta içeren düğümler.

3.2.2.3. Rastgele Orman (Random Forest)

Tumer & Ghosh, (1996), bir sonucu tahmin etmek için birden çok sınıflandırıcının çıktısını birleştirmenin çok yüksek sınıflandırma doğruluğu verdiğini kanıtlamış. Bu, maksimum oylamaya dayalı olarak yeni girdi verilerinin etiketine karar vermek için birden çok karar ağacından gelen çıktıyı birleştiren topluluk sınıflandırıcısı Rastgele Orman 'nin temelidir.

Rastgele Orman, tek bir ağaç oluşturmak için değiştirme yoluyla eğitim örneğinin bir alt kümesini rastgele seçer. bu, her ağaç için verilerin orijinal tam eğitim kümesinden örneklendiği bir torbalama tekniği kullanır. Bu yaklaşım, farklı ağaçlar için aynı örneklerin seçilmesine veya bazı örneklerin hiç seçilmemesine neden olabilir (Bbeiman, 1996).

Eğitim için kullanılmayan örnekler, sınıflandırıcının performansını değerlendirmek ve genelleme hatasının tarafsız bir tahminini sağlamak için dahili olarak kullanılır. Ayrıca, her düğümde Rastgele Orman, bir ağaç oluşturmak için en iyi bölünmeyi belirlemek üzere eğitim örneklerinden rastgele değişken seçimi gerçekleştirir. Bu, tek tek ağaçların gücünü azaltabilse de, ağaçlar arasındaki korelasyonu azaltarak daha düşük genelleme hatasına neden olur (Breiman, 2001).

En iyi ayrımı seçmek için Rastgele Orman, bir düğüm içindeki safsızlık ölçüsünü veren Gini Endeksi ölçüsünü kullanır. Bölme, entropide bir azalma ve bölmeden sonra bilgi kazancında bir artış olacak şekilde gerçekleştirilir. Ancak ağaç tabanlı sınıflandırıcıların performansı en iyi bölünmüş seçim ölçüsünden çok, budama yöntemlerinin seçiminden etkilenir (Pal & Mather, 2003). Rastgele Orman, budama tekniklerini kullanmaya ihtiyaç duymadan ağaç oluşturduğu için bu tür etkilere karşı bağımsızdır (Pal, 2005).

Rastgele Orman için kullanıcı tanımlı parametrelerden biri ağaç sayısıdır. Breiman (1999), ağaç sayısı arttıkça genelleme hatasının her zaman yakınsadığını öne sürer. Dolayısıyla, Büyük Sayıların Güçlü Yasası atfedilebilecek fazla uydurma sorunu yoktur. Bu nedenle, Rastgele Orman için, ağaç sayısı mümkün olduğu kadar çok olabilir, ancak belirli bir noktanın ötesinde, ek ağaçlar, sınıflandırıcının performansını iyileştirmeye yardımcı olmaz (Guan et al., 2013).

Tek bir ağaç, tüm girdi özelliklerinin önemini yakalayamayabilir ve sınıflandırma sırasında belirli özellikleri tercih edebilir, ancak ağaçların bir kombinasyonu, eğitim örneklerinden rastgele seçilen tüm özellikleri hesaba katar. Böylece, uzaktan algılama

açısından Rastgele Orman, bir uydu görüntüsünün bantlarından türetilen farklı değişkenlerin göreceli önemini anlaşılmaya yardımcı olur. Rastgele Orman, diğer değişkenleri sabit tutarken rastgele seçilen girdi değişkenlerinden birini kaldırarak her bir değişkeni değerlendirir. Out-of-bag hatasına ve Gini Endeksi düşüşüne dayalı olarak doğruluğu tahmin eder (Ghosh et al., 2014).

Ek olarak, Rastgele Orman, çiftin aynı terminal düğümünde kaç kez bittiğine bağlı olarak seçilen iki örneğin yakınlığını da ölçer. Bu yakınlık analizi, yanlış etiketlenmiş eğitim örneklerinin saptanmasına yardımcı olur ve Rastgele Ormanı gürültüye karşı duyarsız hale getirir (Rodriguez-Galiano et al., 2012). Rastgele Orman, gürültüye ve aykırı değerlere karşı sağlamlığı nedeniyle önem kazanmıştır (Gislason et al., 2006). Bu çalışmada kullanılan Rastgele Orman yönteminin parametreleri, Tablo 3.9'da gösterilmektedir.

Tablo 3.9. *Rastgele Orman yönteminin parametreleri*

Parametreler	Değer	Açıklama
numberOfTrees	100	Oluşturulacak karar ağaçlarının sayısı.
minLeafPopulation	1	Eğitim seti en az bu kadar nokta içeren düğümler.
BagFraction	0.5	Ağaç başına torbaya girdi oranı.
Seed	0	Rastgeleleştirme tohumu.

3.2.2.4. Gradyanla Güçlendirilmiş Ağaçlar (*Gradient Boosted Trees*)

Gradyanla Güçlendirilmiş Ağaçlar, yanıt değişkeninin daha doğru bir tahminini sağlamak için birçok zayıf öğrenciyi sırayla eğiten bir algoritmadır. Zayıf bir öğrenci, şansttan biraz daha iyi performans gösteren bir makine öğrenimi modelidir. Gradyanla Güçlendirilmiş Ağaçlar söz konusu olduğunda, zayıf öğrenciler genellikle yüzeysel karar ağaçlarıdır. Her bir ağacın tahminlerinin toplandığı bir topluluk modeli oluşturulur. Her yeni ağaç, önceki tüm ağaçların bir kombinasyonu ile ilişkilendirilen kayıpları en aza indirmeye çalışır. Bu şekilde, Gradyanla Güçlendirilmiş Ağaçlar, tahmin doğruluğunu artırmak için birçok zayıf öğrenciyi bir araya getirir.

Kayıp fonksiyonu, gerçekleştirilen görevin türüne bağlıdır ve kullanıcı tarafından seçilebilir. Regresyon için standart seçenek kare kaybı olabilir. Kayıp fonksiyonunu en aza indiren ve genel kayıp fonksiyonunun gradyanını takip eden şekilde, ardışık olarak ağaçlar eklenir. Bu şekilde, genel tahmin hatası azaltılır.

Pek çok hiper-parametrenin gradyan artırıcı ağaçlar için ayarlanması gerekir. Bazıları öğrenme oranı ve kullanılacak ağaç sayısı gibi gradyan artırma sürecini kontrol ederken, diğerleri minimum düğüm boyutu, kullanılacak örnek sayısı ve maksimum derinlik gibi ağaçların inşa sürecini düzenler. Bu hiper-parametrelerin doğru şekilde ayarlanması, modelin performansını önemli ölçüde etkileyebilir. Örneğin, öğrenme oranı aşırı derecede yüksekse, modelin aşırı uyumlu olma eğilimi vardır. Benzer şekilde, ağaçların maksimum derinliği çok büyükse, model aşırı karmaşık hale gelebilir ve aşırı uyuma yol açabilir. Diğer yandan, minimum düğüm boyutu veya kullanılan örnek sayısı çok düşükse, ağaçlar fazla dallanır ve model karmaşık hale gelir. Bu nedenle, hiper-parametrelerin dikkatli bir şekilde ayarlanması ve optimal bir denge bulunması önemlidir. Genellikle çapraz doğrulama veya diğer model değerlendirme teknikleri kullanılarak en iyi hiper-parametreler seçilir. Bu şekilde, gradyan artırıcı ağaçlar, geniş bir model yelpazesi için güçlü ve esnek bir makine öğrenimi algoritması olarak kullanılabilir (Callens et al., 2020).

Gradyanla Güçlendirilmiş Ağaçlar ve Rastgele Ormanlar, ayrı ayrı ağaçlardan elde edilen çıktıları birleştirerek regresyon veya sınıflandırma gerçekleştiren birleştirme yöntemleridir. Her iki yöntem de birçok karar ağacını birleştirir ve bunu her ağacın gereğinden fazla takılması riskini azaltmak için yapar. Ancak, tek tek ağaçların oluşturulma biçimi ve sonuçların bir araya getirilme biçimi bakımından farklılık gösterirler. Rastgele Ormanlar, bağımsız karar ağaçları oluşturmak ve bunları paralel olarak birleştirmek için torbalamayı kullanır. Öte yandan, Gradyanla Güçlendirilmiş Ağaçlar, boosting adı verilen bir yöntem kullanır. Boosting, zayıf öğrenicileri (genellikle tek bölmeli karar ağaçları) sırayla birleştirir, böylece her yeni ağaç bir öncekinin hatalarını düzeltir (Cheshta Dhingra, 2020). Bu çalışmada kullanılan Gradyanla Güçlendirilmiş Ağaçlar yönteminin parametreleri, Tablo 3.10'da gösterilmektedir.


Tablo 3.10. Gradyanla Güçlendirilmiş Ağaçlar yönteminin parametreleri

Parametreler	Değer	Açıklama
numberOfTrees	100	Oluşturulacak karar ağaçlarının sayısı.
Shrinkage	0.005	(0, 1]'deki shrinkage parametresi, prosedürün öğrenme oranını kontrol eder.
samplingRate	0.7	Stokastik ağaç güçlendirme için örnekleme oranı.
Seed	0	Rastgeleleştirme tohumu.

3.2.3. Yapılan çalışmalar

Bu çalışmada, şekil 3.7'de görüldüğü gibi bir yol izlenmiştir. Yapılan çalışma yedi ana bölümden oluşmaktadır. Bu bölümler şunlardır:

- Çalışmada kullanılan uydu görüntüleri seçmek
- Medyan yöntemiyle görüntülerin mozaïği
- Test ve eğitim örneklerini belirtmek
- Seçtiğimiz dört algoritma ile sınıflandırmak (Rastgele orman, SVM, CART, Gradyanla Güçlendirilmiş Ağaçlar)
- Sınıflandırma sonuçlarının doğruluk değerlendirmesi (genel doğruluk, kappa katsayısı, hata matrisi)
- Sınıflara ait alan hesaplaması
- En iyi yöntem ile değişim analizi yapmak



Şekil 3.7. Porsuk Havzası'na ait değişim analizin akış şeması

3.2.3.1. Çalışmada kullanılan uydu görüntülerini seçmek

İlk aşamada atmosferik, radyometrik ve geometrik düzeltmeler gerektirmeyen Landsat uydu koleksiyon 2 Seviye 2 görüntülerini seçilmiştir. Bu görüntüler iki kategoriden oluşmaktadır: top of atmosphere (TOA) yansıma ve yüzey yansıma. Bu iki kategoriden, yüzey yansıma görüntüleri seçilmiştir.

Haziran 2003'ten bu yana, Tarama Hattı Düzelticisi (SLC) arızasından dolayı 2009 yılına ait Landsat 7 görüntülerini seçilmemiştir. Bunun yerine, Landsat 5 koleksiyon 2 seviye 2 uydusuna ait TM (Thematic Mapper) algılayıcısı görüntülerini kullanılmıştır. Ayrıca, 2000 yılına ait Landsat-7 koleksiyon 2 seviye 2 uydusuna ait ETM+ (Enhanced Thematic Mapper Plus) algılayıcısı görüntülerini ve 2020 yılına ait Landsat-8 koleksiyon 2 seviye 2 uydusuna ait OLI/TIRS (Operational Land Imager/Thermal Infrared Sensor) algılayıcısı görüntüleri kullanılmıştır.

Daha sonra seçilen görüntülere mekansal filtre uygulanmıştır. Bu filtreyi uygulamak için Porsuk Havzası'na ait Shapefile'ı Google Earth Engine platformuna eklenmiştir. Ardından, Landsat görüntülerine zamansal filtre uygulanmıştır. Bu filtre, görüntülerin çekildiği tarihlerin birbirine mümkün olduğunca yakın ve aynı ay içinde seçilmesini sağlayacak şekilde tanımlanmıştır.

Daha sonra görüntülere %3'ten daha az bir bulut filtresi uygulanmıştır. Bu filtreleme işleminden sonra, 2000 yılına ait görüntülerde neredeyse hiç bulut bulunmazken, 2009 ve 2020 yıllarına ait görüntülerde bulut oranı sıfıra yakın olarak seçilmiştir. Bulut yüzdesi %3'ün üzerinde olan görüntülerin sınıflandırma sürecinde sorunlara neden olduğu göz önünde bulundurulmuştur. Çalışma alanı dört adet Landsat görüntüsünü içermektedir ve geniş bir alanı kapsadığından, uygun görüntülerin seçimi zorlu olmuştur. Ancak, bu koşulları göz önünde bulundurarak, hem tarih hem de bulut oranı açısından en uygun görüntüler seçilmiştir: Landsat-7 uydusuna ait 04.07.2000, 04.07.2000, 27.07.2000 ve 27.07.2000 tarihli ve Landsat-5 ait 22.08.2009, 22.08.2009, 29.08.2009 ve 29.08.2009 tarihli ve Landsat-8 uydusuna ait 04.08.2020, 04.08.2020, 27.08.2020 ve 27.08.2020 tarihli görüntüleridir.

Landsat Seviye-2 ürünleri, verileri dağıtım için ondalık sayıdan tam sayıya dönüştürmek için ölçekli tam sayılar olarak yazılmıştır. Bu, disk alanından tasarruf sağlar ve daha hızlı indirme süreleri sağlar. Genellikle, bu tam sayılar 16 bitlik bir tamsayıya yazılır. Her piksel değerine bir ofset uygulanır ve ardından değeri 16 bitlik tamsayı aralığına getirmek için bir kazançla çarpılır. Bu, ölçeklendirilmiş tamsayılar olarak

bilinir. Kullanıcının verileri orijinal kayan nokta değerine geri döndürmesine olanak sağlamak için her bant için bir ölçek faktörü ve ofset sağlanır. Ölçek faktörü her piksele uygulanır ve ardından ofset eklenir (örneğin, Dijital Sayı (DN) * ölçek_faktörü + ofset). Bu çalışmada Landsat görüntülerinin optik bantları ve termal bantları kullanılmıştır. Her birinin kendine özgü kazanç ve ofset değerleri vardır. Bu faktörlerin uygulanması, Şekil 3.8'da görülmektedir.

```
//define scaling factors.
function applyScaleFactors(image) {
  var opticalBands = image.select('SR_B.').multiply(0.0000275).add(-0.2);
  var thermalBands = image.select('ST_B.*').multiply(0.00341802).add(149.0);
  return image.addBands(opticalBands, null, true)
    .addBands(thermalBands, null, true);
}
```

Şekil 3.8. Ölçek faktörü uygulaması için yazılan kod

Aldığımız tüm uydu görüntülerinin İzlediği Yolu 179 ve 178 ve Görüntü Sırası 32 ve 33 şeklindedir. Ancak genel olarak, görüntülenme tarihlerinde algılayıcılar normal şekilde çalışmakta ve görüntüde anormal bir durumla karşılaşmamıştır. Ayrıca, tüm bantlarda görüntü kalitesi algılayıcı tarafından algılanabilecek en üst düzeydedir. Yukarıda açıklanan her aşamanın kodları Landsat 8 için, Şekil 3.9'da, Landsat 7 için Şekil 3.10'da ve Landsat 5 için Şekil 3.11'de görülmektedir.

```
// define collection
var landsat8 = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
  .filterBounds(Porsuk_Havza)
  .filterDate(startdate, enddate)
  .filter(ee.Filter.lessThan('CLOUD_COVER',3))
  .map(applyScaleFactors)
  .filter(ee.Filter.or(
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 32)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 32))))
  .map(ndvi)
  .map(ndbi)
  .map(ndwi)
  .map(ui)
  .map(bui)
  .map(baei)
  .map(brba)
  .map(nbi);

print('landsat8',landsat8.sort('system:time_start'));
var bands = ['SR_B1', 'SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7', 'ST_B10', 'ndvi', 'ndbi', 'nbi', 'ndwi'];
```

Şekil 3.9. Seçtiğimiz Landsat 8 uydusunun uygulanması için yazılan kodlar

```
// define collection
var landsat7 = ee.ImageCollection('LANDSAT/LE07/C02/T1_L2')
  .filterBounds(Porsuk_Havza)
  .filterDate(startdate, enddate)
  .filter(ee.Filter.lessThan('CLOUD_COVER',3))
  .map(applyScaleFactors)
  .filter(ee.Filter.or(
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 32)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 32))))
  .map(ndvi)
  .map(ndbi)
  .map(ndwi)
  .map(ui)
  .map(bui)
  .map(baei)
  .map(brba)
  .map(nbi);

print('landsat7',landsat7.sort('system:time_start'));

var bands = ['SR_B1','SR_B2','SR_B3','SR_B4','SR_B5','SR_B7','ST_B6','ndvi','ndbi','nbi','ndwi'];
```

Şekil 3.10. Seçtiğimiz Landsat 7 uydusunun uygulanması için yazılan kodlar

```
// define collection
var landsat5 = ee.ImageCollection('LANDSAT/LT05/C02/T1_L2')
  .filterBounds(Porsuk_Havza)
  .filterDate(startdate, enddate)
  .filter(ee.Filter.lessThan('CLOUD_COVER',3))
  .map(applyScaleFactors)
  .filter(ee.Filter.or(
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 179),
      ee.Filter.eq('WRS_ROW', 32)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 33)),
    ee.Filter.and(ee.Filter.eq('WRS_PATH', 178),
      ee.Filter.eq('WRS_ROW', 32))))
  .map(ndvi)
  .map(ndbi)
  .map(ndwi)
  .map(ui)
  .map(bui)
  .map(baei)
  .map(brba)
  .map(nbi);

print('landsat5',landsat5.sort('system:time_start'));

var bands = ['SR_B1','SR_B2','SR_B3','SR_B4','SR_B5','SR_B7','ST_B6','ndvi','ndbi','nbi','ndwi'];
```

Şekil 3.11. Seçtiğimiz Landsat 5 uydusunun uygulanması için yazılan kodlar

Çalışmada indekslerin arasındaki korelasyona göre kullanılan materyal olarak, NDVI, NDWI, NDBI ve NBI indeksleri seçilmiş ve iki farklı veri seti oluşturulmuştur:

- Veri seti 1: Landsat multispektral bantlar (B1, B2, B3, B4, B5, B6, B7)

- Veri seti 2: Landsat multispektral bantlar (B1, B2, B3, B4, B5, B6, B7), Landsat termal bantlar, NDVI , NDBI , NBI , NDWI ve bu indekslerin açıklaması için yazılan kodlar, Şekil 3.12'de görülmektedir.

```
// define NDVI
function ndvi (image){
  var first = image
  var second = image.normalizedDifference(['SR_B5', 'SR_B4']).rename('ndvi')
  return first.addBands(second)
}

// define NDBI
function ndbi(image){
  var first = image
  var second = image.normalizedDifference(['SR_B6', 'SR_B5']).rename('ndbi')
  return first.addBands(second)
}

// define NDWI
function ndwi(image){
  var first = image
  var second = image.normalizedDifference(['SR_B3', 'SR_B5']).rename('ndwi')
  return first.addBands(second)
}

// define NBI
function nbi(image){
  var first = image
  var nbi = image.expression(
    '(swir * red) / (nir)',
    {
      'red' : image.select('SR_B4'),
      'swir': image.select('SR_B6'),
      'nir': image.select('SR_B5')
    }
  );

  var second = nbi.rename('nbi')
  return first.addBands(second)
}
```

Şekil 3.12. İndekslerin açıklanması için yazılan kodlar

3.2.3.2. Medyan yöntemiyle görüntülerin mozaïği

Mozaik, bitişik alanların birden fazla görüntüsünün tek bir görüntüde birleştirilmesiyle oluşturulan kompozit bir görüntüdür. Google Earth Engine (GEE) platformunda, ee.ImageCollection.mosaic() yöntemini kullanarak koleksiyondaki tüm görüntüleri coğrafi konumlarına göre birleştirerek bir mozaik görüntü oluşturabilir. Oluşturulan mozaik görüntü, değerlendirilen noktaya en yakın olan görüntüden piksel değerleri seçilerek oluşturulur. Görüntüler medyan, maksimum veya minimum gibi farklı

seenekler kullanarak birleřtirilebilir. Bu üç yöntem arasından Medyan yöntemi, mozaikleme işlemi için seçilmiştir.

Porsuk Havzası dört adet Landsat görüntüsü içermektedir. Bu nedenle öncelikle her yıla ait dört görüntüyü Medyan yöntemiyle mozaikleyerek tüm havzayı kapsayan tek bir görüntü elde edilmiş ve bu işlem, 2000, 2009 ve 2020 yılları için gerçekleştirilmiştir. Bir sonraki adımda, elde edilen bütünleşik görüntünün Porsuk Havzası'nın ShapeFile'ını kullanarak klip işlemi yapılmıştır (Bkz. Şekil 3.13).

```
// Mosaic
var Mosaic = landsat8.select(bands)
    .median()
    .clip(Porsuk_Havza);

Map.addLayer(Mosaic,{min:0.1,max:0.4,bands:['SR_B4','SR_B3','SR_B2']},'Mosaic');

// scale
var scale = landsat8.first().select(0).projection().nominalScale().getInfo();
print(scale);
```

Şekil 3.13. Görüntülerin mozaik ve klip için yazılan kodlar

3.2.3.3. Test ve eğitim örneklerini belirtmek

Porsuk Havzası'nı sekiz farklı sınıfa ayırmak için her sınıfın eğitim ve test örneklerini belirlenmiştir. Bu sekiz sınıf şunlardır: ormanlar, seyrek ormanlar, yaş tarım alanları, kuru tarım alanları, yapay yüzeyler, su alanları, toprak ve meralar. Havzanın her bölgesine uygun dağılıma sahip, yüksek doğrulukta, her sınıf için eğitim örnekleri eklenmiştir. Eğitim örnekleri nokta olarak belirlenmiştir.

Eğitim örnekleri seçimi, tezin en fazla zaman alan aşamalarından biridir. Her eğitim örneğinin yüksek doğrulukla seçilmesi gerektiği için bu sürece özel önem verilmektedir. Kullanılan algoritmalar, bu eğitim örneklerinin üzerinde eğitilir ve ardından sınıflandırma işlemi gerçekleştirilir. Bu nedenle eğitim örneklerinin yüksek doğrulukla seçilmesi büyük önem taşımaktadır.

Sınıflandırmanın ardından algoritmaları doğrulamak amacıyla , 2000, 2009 ve 2020 yıllarına ait Landsat görüntülerine her sınıf için test örnekleri eklenmiştir. Bu test örnekleri yerden temel gerçek verilerine dayanmalıdır. Ancak bu verilerin eksikliği nedeniyle test örnekleri, Google Earth uygulamasının görüntülerini inceleyerek her yıl için eklenmiştir. Eğitim ve test örneklerinin Google Earth Engine platformda belirlenmesi için yazılan kodları, Şekil 3.14 ve Şekil 3.15'te görülmektedir.

```

var training_data = Orman.merge(Tarim_arazi).merge(Yerlesim_alani)
.merge(Su).merge(Seyrak_orman).merge(Toprak).merge(Tarim_arazi_k).merge(Mera);

var training = Mosaic.sampleRegions({
  collection : training_data,
  properties : ['Landcover'],
  scale : 30,
  tileScale: 10
});

```

Şekil 3.14. Eğitim örneklerinin belirlmesi için yazılan kodlar

```

var test_data = Orman_test.merge(Tarim_arazi_test).merge(Yerlesim_alani_test).merge(Su_test)
.merge(Seyrak_orman_test).merge(Toprak_test).merge(Tarim_arazi_k_test).merge(Mera_test);

var validation = Mosaic.sampleRegions({
  collection : test_data,
  properties : ['LandUse'],
  scale : 30,
  tileScale: 10
});

```

Şekil 3.15. Test örneklerin belirlmesi için yazılan kodlar

3.2.3.4. Seçtiğimiz dört algoritma ile sınıflandırma

Çalışma alanına ait Landsat görüntülerini sınıflandırmak için dört farklı algoritma kullanılmıştır: Rastgele Orman, Destek Vektör Makineleri (SVM), Gradyanla Güçlendirilmiş Ağaçlar ve Sınıflandırma ve Regresyon Ağaçları (CART).

Sınıflandırma iki veri seti kullanarak gerçekleştirilmiştir. İlk veri seti olarak sadece Landsat uydusunun optik bantları kullanılmıştır. İkinci veri seti olarak ise Landsat uydusunun optik bantlarına ek olarak termal bant ve spektral indeksler (NDVI, NDWI, NDBI ve NBI) kullanılmıştır.

İki veri seti ile sınıflandırma haritaları oluşturarak bu iki veri setin performansını karşılaştırılmıştır. Çalışma alanına ait Landsat görüntülerini sınıflandırmak için Google Earth Engine'i kullanılmıştır. CART, SVM, Rastgele Orman ve Gradyanla Güçlendirilmiş Ağaçlar algoritmanın uygulamak için yazılan kodlar, sırasıyla Şekil 3.16, Şekil 3.17, Şekil 3.18 ve 3.19'da görülmektedir.

```

var classifier = ee.Classifier.smileCart(100)
.train({
  features: training,
  classProperty: 'Landcover',
  inputProperties: bands
});

var classified = Mosaic.classify(classifier);

print(classified);
Map.addLayer(classified,{min:0, max:7,
  palette : ['#066b03','#f0ff5d','#f30000','#0f30ff','#10df09','#886e42','#e68500','#abd6a4']
});

```

Şekil 3.16. CART yöntemini uygulamak için yazılan kodlar

```

var classifier = ee.Classifier.libsvm({kernelType:"poly",degree:3,coef0:0.5,cost:15,gamma:0.1})
.train({
  features: training,
  classProperty: 'Landcover',
  inputProperties: bands
});

var classified = Mosaic.classify(classifier);

print(classified);
Map.addLayer(classified,{min:0, max:7,
  palette : ['#066b03','#f0ff5d','#f30000','#0f30ff','#10df09','#886e42','#e68500','#abd6a4']
});

```

Şekil 3.17. SVM yöntemini uygulamak için yazılan kodlar

```

var classifier = ee.Classifier.smileRandomForest(100)
.train({
  features: training,
  classProperty: 'Landcover',
  inputProperties: bands
});

var classified = Mosaic.classify(classifier);

print(classified);
Map.addLayer(classified,{min:0, max:7,
  palette : ['#066b03','#f0ff5d','#f30000','#0f30ff','#10df09','#886e42','#e68500','#abd6a4']
});

```

Şekil 3.18. Rastgele Orman yöntemini uygulamak için yazılan kodlar

```

var classifier = ee.Classifier.smileGradientTreeBoost(100)
.train({
  features: training,
  classProperty: 'Landcover',
  inputProperties: bands
});

var classified = Mosaic.classify(classifier);

print(classified);
Map.addLayer(classified,{min:0, max:7,
  palette : ['#066b03','#f0ff5d','#f30000','#0f30ff','#10df09','#886e42','#e68500','#abd6a4']
});

```

Şekil 3.19. Gradyanla Güçlendirilmiş Ağaçlar yöntemini uygulamak için yazılan kodlar

3.2.3.5. Sınıflandırma sonuçlarının doğruluk değerlendirmesi

Sınıflandırma algoritmalarının performansını değerlendirmek için, yazılan kodlar Şekil 3.20 ve Şekil 3.21'de gösterilmektedir. Algoritmaları birbiriyle kıyaslamak için Kappa katsayısı ve genel doğruluk kullanılmıştır. Ayrıca hata matrislerin sonuçları, hangi yöntemin hangi sınıfı doğru şekilde sınıflandırdığını göstermek için kullanılmıştır. Kappa katsayısı ve genel doğruluk, Porsuk Havzası'ndaki değişim analizinde hangi yöntemin daha iyi sonuç vereceğini belirlemek için kullanılmıştır.

```

var trainAccuracy = classifier.confusionMatrix();
print('Resubstitution error matrix: ', trainAccuracy);
print('Training overall accuracy: ', trainAccuracy.accuracy());

```

Şekil 3.20. Eğitim örneklerinin doğruluk değerlendirmesi için yazılan kodlar

```

var validated = validation.classify(classifier);
var testAccuracy = validated.errorMatrix('LandUse', 'classification');
print('Validation error matrix: ', testAccuracy);
print('Validation overall accuracy: ', testAccuracy.accuracy());
print('Kappa statistic', testAccuracy.kappa());

```

Şekil 3.21. Test örneklerinin doğruluk değerlendirmesi için yazılan kodlar

3.2.3.6. Sınıflara ait alan hesaplanması

Porsuk Havzası Porsuk Havzası'ndaki değişiklikleri belirlemek için, seçtiğimiz dört algoritma ile yapılan sınıflandırma sonrasında, her sınıfın kapsadığı alan hesaplanmıştır. Bu hesaplama, havza içindeki farklı toprak kullanımı ve arazi örtüsü alanlarının miktarlarını anlamamıza ve değişimlerini izlememize yardımcı olmaktadır. Şekil 3.22'de

uygulanan kod yardımıyla seçtiğimiz en iyi iki yöntem ile, her sınıfa ait alan hesaplanmıştır.

```
var class_areas = ee.Image.pixelArea().addBands(classified).divide(1e6)
  .reduceRegion({
    reducer: ee.Reducer.sum().group(1),
    geometry: Porsuk_Havza,
    scale: 30,
    bestEffort: true,
    tileScale: 10
  });


print('All Classes Area', class_areas);
```

Şekil 3.22. Sınıflara ait alanın hesaplanması için yazılan kodlar

3.2.3.7. En iyi yöntem ile değişim analizi yapmak


Porsuk Havzası'nda 2000 ile 2020 yılları arasındaki 20 yıllık süreçteki arazi kullanım haritaları, Google Earth Engine platformu kullanılarak oluşturulmuştur. Çalışma alanındaki değişiklikleri analiz etmek için en iyi algoritmayı seçmek amacıyla genel doğruluk, hata matrisi ve Kappa katsayıları içeren sonuçlar karşılaştırılmıştır. Bu karşılaştırmalar sonucunda çalışma alanındaki değişimi analiz etmek için en iyi algoritma belirlenmiştir. Belirlenen en iyi algoritma ile her sınıfın arazi kullanımındaki değişim miktarı hesaplanmıştır.

sürdürülebilir kullanım için gerekli kararları almak için önemli bir araçtır (Çellek, 2020). Porsuk Havzası'nın eğim haritası Şekil 4.3'te gösterilmektedir.



4.1.1.4. Akış yönü haritası


Akış Yönü haritası, bir bölgedeki su kaynaklarının akış yönlerini gösteren bir haritadır. Bu harita, bir bölgedeki akarsuların, nehirlerin ve diğer su kaynaklarının nasıl birbirine bağlandığını ve hangi yönde aktığını gösterir. Akış yönü haritaları, özellikle hidroloji, havza yönetiminde, çevre planlaması ve su kaynakları yönetimi gibi alanlarda kullanılır (Gruber & Peckham, 2009). Porsuk Havzası'nın akış yönü haritası Şekil 4.4'te gösterilmektedir.



Şekil 4.4. Akış yönu haritası

4.1.1.5. Bakı haritası

Bakı haritası, bir bölgenin yüzeyindeki eğimlerin yönlerini gösteren bir haritadır. Bu harita, bir bölgenin topoğrafik özelliklerini gösterir ve özellikle inşaat, tarım, ormancılık, madencilik ve çevre planlaması gibi alanlarda kullanılır. Eğim yönu haritaları, bir bölgenin yüzeyindeki eğimlerin yönlerini gösterir ve bu eğimlerin yönleri, bir bölgedeki su kaynaklarının akış yönlerini belirlemek için önemlidir (Malaperdas & Panagiotidis, 2018). Bu harita Sayısal Yükseklik Modelini kullanılarak oluşturulmuştur. Porsuk Havzası'nın Bakı haritası Şekil 4.5'te gösterilmektedir.



Şekil 4.5. Baki haritası


4.1.2. Sınıflandırma

Sınıflandırma, uzaktan algılama verilerinin analizinde önemli bir adımdır. Bu işlem, elde edilen verilerin farklı arazi örtüsü sınıflarına ayrılmasını sağlar. Sınıflandırma, arazi kullanımı, tarım, ormancılık, su kaynakları yönetimi gibi birçok alanda kullanılmaktadır. Bu bölümde, Google Earth Engine platformunda dört farklı yöntem kullanılarak sınıflandırma haritaları üretilmiştir.

4.1.2.1. Rastgele Orman


Rastgele Orman, sınıflandırma, regresyon ve diğer görevler için kullanılan bir topluluk öğrenme yöntemidir. Bu yöntem, birçok karar ağacı üzerinden her bir karar ağacını farklı bir gözlem örneği üzerinde eğiterek çalışır. Bu sayede, birden fazla karar ağacının çıktısı bir araya getirilerek daha doğru ve istikrarlı bir tahmin elde edilir (Belgiu & Drăgu, 2016).

Rastgele Orman yöntemi kullanılarak sınıflandırılmış görüntüler, 2000, 2009 ve 2020 yılları için iki veri seti kullanılarak aşağıda gösterilmiştir.




Şekil 4.6. Rastgele Orman yöntemiyle 2000 Tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.6'da yer alan 2000 yılına ait haritasında görüldüğü gibi, birinci veri seti ve Rastgele Orman yöntemini kullanarak yapılan sınıflandırmada, kırmızı ile işaretlenen kentsel alanlar yanlışlıkla toprak sınıfında görülmektedir. Bu hata özellikle havzanın güney kısmında kırsal alanlarda meydana gelmektedir. Bu hatanın nedeni kırsal bölgelerde toprak ile yapay yüzeylerin ayırt edilmesinin zorluğudur. Mavi renkle işaretlenen su alanları genellikle doğru bir şekilde sınıflandırılmıştır ve bu sınıfın bazı yerlerde yaş tarım araziler sınıfına karışması nemin varlığından kaynaklanmaktadır. İlk veri setini kullandığımızda orman ile yaş tarım alanlarını ayırt etmek zor olmamış, bu sınıflar sırasıyla yeşil ve sarı renklerle gösterilmiştir. Ancak turuncu kuru tarım alanlarının birçok yerde kahverengi toprak olarak sınıflandırılması, sınıflandırma doğruluğunu azaltmıştır. Açık maviyle işaretlenmiş meralar genellikle iyi sınıflandırılmış ancak bazı yerlerde seyrek ormanlarla karışmıştır. İlk veri seti kullanarak, Rastgele Orman yöntemi toprak sınıfı sınıflandırmasında hata yapmış ve bazı noktalar mera sınıfına, bazıları ise seyrek orman sınıfına yerleştirilmiştir.




Şekil 4.7. Rastgele Orman yöntemiyle 2000 Tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.7'de yer alan 2000 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve Rastgele Orman yöntemini kullanarak yapılan sınıflandırmada, yeşil renkle gösterilen ormanlar yüksek doğrulukla sınıflandırılmıştır. Ayrıca sarı renkle gösterilen yaş tarım alanları da yüksek doğrulukla sınıflandırılmıştır. Rastgele Orman algoritması açık mavi renkle işaretlenen meraların sınıflandırılmasında diğer algoritmalara göre daha iyi performans göstermiştir. Bu yöntemle meralar %90'ın üzerinde doğrulukla sınıflandırılmıştır. Sırasıyla mavi, açık yeşil ve kahverengi renklerle gösterilen su alanları, seyrek ormanlar ve toprak için seçilen test örnekleri %85'in üzerinde bir doğrulukla sınıflandırılmıştır. Turuncuyla gösterilen kuru tarım alanlar diğer sınıflara göre daha az doğrulukla sınıflandırılmış, yani test numunelerinin %25'i hatalı olarak toprak sınıfında sınıflandırılmış ve sınıflandırmadaki bu hata havzanın kuzeybatısında daha belirgindir. Havzanın güney kısmında kırmızı renkte olan kentsel alanlar %20 yanlışlıkla toprak sınıfı olarak sınıflandırılmıştır. Ancak ikinci veri seti kullanıldığında sınıflandırma ilk veri setine göre daha doğru harita elde etmiş ve termal bant ve indeks kullanımının etkisi göstermektedir.




Şekil 4.8. Rastgele Orman yöntemiyle 2009 Tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.8'de yer alan 2009 yılına ait haritasında görüldüğü gibi, ilk veri seti ve Rastgele Orman yöntemini kullanarak yapılan sınıflandırmada, Ormanlar ve yaş tarım alanları doğru şekilde sınıflandırılmış ve bu sınıflar sırasıyla yeşil ve sarı renklerle işaretlenmiştir. Bu yöntem ile kırmızı renkle gösterilen kentsel alanlar, iyi bir doğrulukla sınıflandırılmıştır. Mavi renkle işaretlenen su alanları büyük oranda doğru tespit edilmiş ve diğer sınıflara müdahale etmemiştir. Bu yöntemle seyrek orman sınıfı iyi sınıflandırılmış ancak eğitim örneklerinden bazıları beklendiği gibi orman sınıfı ile karıştırılmıştır. Bu veri setindeki Rastgele Orman yöntemi, toprak sınıfını sınıflandırmada hata yapmış ve bazı kısımlar yanlışlıkla mera sınıfına, bazıları ise yapay yüzeyler sınıfına yerleştirilmiştir. İlk veri setini kullandığımızda, kuru tarım alanları birçok yerde toprak olarak sınıflandırılmış ve meralarla örtüşmüş, bu da sınıflandırma doğruluğunu azaltmıştır. Açık mavi renkle işaretlenen meralar, bazı yerlerde seyrek ormanlarla, bazı yerlerde ise toprakla karışmıştır. Mera, seyrek orman ve toprak sınıfları arasındaki karışma, meraları seyrek orman ve topraktan ayırmanın zor olmasından kaynaklanır çünkü bu sınıfların görsel olarak bile ayrılması zordur.




Şekil 4.9. Rastgele Orman yöntemiyle 2009 Tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.9'da yer alan 2009 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve Rastgele Orman yöntemini kullanarak yapılan sınıflandırmada, Sırasıyla mavi, yeşil ve sarı renklerle işaretlenen su yüzeyleri, ormanlar ve yaş tarım alanlar çok yüksek doğrulukla sınıflandırılmış ve diğer sınıflarla hiçbir etkileşime girmemiştir. İkinci veri setinde kentsel ve toprak alanlar %95'in üzerinde doğrulukla sınıflandırılmış, bu durum termal bant ve indekslerin kullanılmasının önemini açıkça göstermektedir. Açık mavi renk ile gösterilen meralar iyi bir doğrulukla sınıflandırılmış ve bu sınıfa ait yalnızca az sayıda test numunesi toprak sınıfıyla örtüşmektedir. Turuncuyla gösterilen kuru tarım alanları diğer sınıflara göre daha az doğrulukla sınıflandırılmıştır. Test örneklerin %20'si toprak sınıfında, %5'i ise mera sınıfında yanlış sınıflandırılmış ve sınıflandırmadaki bu hata havzanın kuzeybatısında daha sık gözlenmiştir. Bu sınıflar arasındaki karışmanın nedeni, büyük benzerliklerinden kaynaklanabilir. Açık yeşil ile gösterilen seyrek ormanlar, sınıflandırmada yaş tarım ve orman sınıflarıyla çok az örtüşmektedir. Ancak ikinci veri seti kullanıldığımızda ilk veri setine göre daha doğru bir sınıflandırma haritası elde edilmiş ve aynı zamanda termal bant ve indeksler kullanımının etkisi daha belirgin hale getirmiştir.



Şekil 4.10. Rastgele Orman yöntemiyle 2020 Tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.10'da yer alan 2020 yılına ait haritasında görüldüğü gibi, ilk veri seti ve Rastgele Orman yöntemi kullanılarak yapılan sınıflandırmada, ormanlar ve kuru tarım alanları doğru şekilde sınıflandırılmış ve bu sınıflar sırasıyla yeşil ve turuncu renklerle işaretlenmiştir. Sarı renkle işaretlenen yaş tarım arazileri yüksek doğrulukla sınıflandırılmıştır. Ayrıca mavi renkteki su alanları, bir önceki sınıfa benzer şekilde yüksek doğrulukla sınıflandırılmıştır. Açık yeşil renkle gösterilen seyrek orman sınıfı yüksek doğruluğa sahiptir ancak orman ve mera sınıflarına müdahale etmektedir. Bu durum bu üç sınıfı birbirinden ayırmanın zorluğundan kaynaklanmaktadır. Meralar, seyrek orman, toprak ve orman sınıflarıyla örtüşebilir, yani meralar genellikle toprak ve otlakların bir karışımını temsil eder. Bu durum, meraları ormanlar ve toprak sınıflarından ayırmayı zorlaştırmıştır. Bu veri setindeki Rastgele Orman yöntemi, toprak sınıfını sınıflandırmada hata yapmış ve bazı noktalar yanlışlıkla mera sınıfına, bazıları ise kuru tarım arazi sınıfına yerleştirilmiştir. Kırmızı renkle işaretlenen yapay yüzeyleri, bazı kısımlarda toprak sınıfında görülmektedir.




Şekil 4.11. Rastgele Orman yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.11'de yer alan 2020 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve Rastgele Orman yöntemini kullanarak yapılan sınıflandırmada, yeşil renkle gösterilen ormanlar genellikle doğru şekilde sınıflandırılmıştır. Ayrıca sarı renkle gösterilen yaş tarım alanları da doğru şekilde sınıflandırılmıştır. Sırasıyla mavi, açık yeşil ve turuncu renklerle gösterilen su alanları, seyrek ormanlar ve kuru tarım arazilerinin sınıflandırmasında Rastgele orman algoritması %95'in üzerinde doğrulukla sınıflandırılmıştır. Kırmızı renkle gösterilen yapay yüzeyler, termal bant ve indeksler kullanımının etkisi altında, ilk veri setine kıyasla %90'in üzerinde bir doğrulukla sınıflandırılmıştır. Kahverengi renkle gösterilen toprak sınıfı, genellikle meralar, kuru tarım arazileri ve seyrek orman sınıflarıyla örtüşmektedir. Sınıflar arasındaki benzerlik nedeniyle bu karışımların varlığı göz ardı edilebilir. Açık mavi renkteki mera sınıfı daha az doğrulukla sınıflandırılmış; dolayısıyla %20'si hatalı olarak seyrek orman sınıfına, %15'i ise toprak sınıfına yerleştirilmiştir. Buna rağmen ikinci veri seti kullanıldığımızda ilk veri setine göre daha doğru sınıflandırma haritası elde edilmiş ve aynı zamanda termal bant ve indeksler kullanımının etkisi görülebilmektedir.

4.1.2.2. Support Vektör Makinesi (SVM)


Destek Vektör Makineleri (SVM), farklı sınıflar arasındaki ayrımı sağlamak için optimal bir hiperdüzlem bulmaya dayalı olarak çalışan sıkça kullanılan bir sınıflandırma algoritmasıdır. SVM, veriler arasındaki karar sınırlarını belirlerken destek vektörlerini kullanır. SVM, uzaktan algılama biliminde sınıflandırma problemlerini çözmek için yaygın bir şekilde kullanılmaktadır (Hsu et al., 2003).

SVM yöntemi kullanılarak sınıflandırılmış görüntüler, 2000, 2009 ve 2020 yılları için iki veri seti kullanılarak aşağıda gösterilmiştir.




Şekil 4.12. SVM yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.12’de yer alan 2000 yılına ait haritada görüldüğü gibi, ilk veri seti ve SVM yöntemi kullanarak elde ettiğimiz haritada sınıflandırma tamamen yanlış yapılmıştır. Havzanın büyük bir kısmı yanlışlıkla orman, seyrek orman, mera ve toprak sınıfları olarak sırasıyla yeşil, açık yeşil, açık mavi ve kahverengi renklerle sınıflandırılmıştır. Öte yandan havzanın yapay yüzeyleri sınıflandırılmamış ve bu sınıfa ait tüm örnekler toprak sınıfına yerleştirilmiştir. Ayrıca, bu algoritma kuru ve yaş tarım alanlarını sırasıyla turuncu ve sarı olarak yanlış sınıflandırmıştır. Sınıflandırma, çalışma alanının sadece orta kısımlarında doğru çalışmıştır ve sadece su alanları doğru şekilde sınıflandırılmıştır.



Şekil 4.13. SVM yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)


Şekil 4.13'te yer alan 2000 yılına ait haritada görüldüğü gibi, ikinci veri seti ve SVM yöntemi kullanılarak elde edilen harita, önceki haritadan belirgin şekilde farklıdır. Ancak, tamamen yanlış sınıflandırmadan nispeten mantıklı bir sınıflandırmaya dönüşmüştür. Yine de diğer yöntemlere göre düşük performans göstermektedir. Bu haritada, yeşil renkle işaretlenen ormanlar ve sarı renkle işaretlenen yaş tarım arazileri doğru bir şekilde sınıflandırılmıştır. Açık mavi renkle gösterilen meralar başarılı bir şekilde sınıflandırılmış ve seyrek ormanlarla çok az etkileşime sahiptir. Diğer taraftan, su alanları da önceki haritadaki gibi başarılı bir şekilde sınıflandırılmıştır. Kırmızı renkli yapay yüzeyler %75'in üzerinde bir doğrulukla sınıflandırılmış ve bu sınıflandırma doğruluğundaki artış, termal bant ve indekslerin kullanımının önemini vurgulamaktadır. Açık yeşil renkle gösterilen seyrek ormanlar %75 doğrulukla sınıflandırılmış ve %25'i ormanlarla karışmıştır. SVM yöntemi, toprak sınıflandırmasında meralar ve seyrek ormanlarla karışmış olup, turuncu renkteki kuru tarım arazileri ise önceki haritaya göre daha doğru bir şekilde sınıflandırılmıştır. İkinci veri seti kullanıldığımızda ilk veri setine göre çok doğru sınıflandırma haritası elde edilmiş ve aynı zamanda termal bant ve indeksler kullanımının etkisi görülebilmektedir.



Şekil 4.14. SVM yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)


Şekil 4.14'te yer alan 2009 yılına ait haritada görüldüğü gibi, ilk veri seti ve SVM yöntemi kullanarak elde ettiğimiz haritada sınıflandırma tamamen yanlış olup, havzanın büyük bir kısmı sırasıyla yeşil, açık yeşil ve kahverengi renkte olan ormanlar, seyrek ormanlar ve toprak olarak sınıflandırılmıştır. Meraların çoğu seyrek ormanlar sınıfında yer almaktadır ve haritada neredeyse hiç açık mavi renkli olan mera sınıfı gözükmemektedir. Kuru tarım arazileri tamamen toprak sınıfında yer almaktadır, bu nedenle haritada turuncu renkteki kuru tarım arazileri bulunmamaktadır.

SVM yöntemini kullandığımızda, havzanın yapay yüzeylerini sınıflandıramamış ve bu sınıfa ait eğitim örneklerinin neredeyse yarısı toprak sınıfında yer almıştır. Bu durum, algoritmanın yapay yüzeylerini tespit edemediğini göstermektedir. Ayrıca, bu algoritma sarı renkte olan yaş tarım alanlarını sınıflandırmada hata yapmış ve havzanın sadece sınırlı kısımlarında, yani orta ve güney kısımlarında doğru sınıflandığı görülmektedir. Bu veri setindeki mavi renkteki su alanları ise büyük oranda doğru şekilde sınıflandırılmıştır.



Şekil 4.15. SVM yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.15'te yer alan 2009 yılına ait haritada görüldüğü gibi, ikinci veri seti ve SVM yöntemi kullanarak elde ettiğimiz harita önceki haritadan çok farklı, dolayısıyla tamamen yanlış bir sınıflandırmadan, nispeten mantıklı bir sınıflandırmaya dönüşmüştür. Bu haritada, sırasıyla yeşil, sarı ve mavi renkteki ormanlar, yaş tarım alanları ve su alanları doğru bir şekilde sınıflandırılmıştır. Kahverengi renkle işaretlenen toprak sınıfı iyi bir şekilde sınıflandırılmış ve meralarla çok az etkileşime sahiptir. Kırmızı renkle işaretlenen yapay yüzeyler ise %75'in üzerinde bir doğrulukla sınıflandırılmıştır. Bu doğruluk artışı, termal bant ve indekslerin kullanılmasının önemini vurgulamaktadır. Açık yeşil ile işaretlenen seyrek ormanlar %75 doğrulukla sınıflandırılmış ve %25'i yanlışlıkla orman sınıfına dahil edilmiştir. Açık mavi renkle işaretlenen meralar, toprakla, seyrek ormanlarla ve yaş tarım arazileriyle örtüşmektedir. Turuncu ile işaretlenen kuru tarım arazileri bir önceki haritaya göre iyi bir şekilde sınıflandırılmıştır. SVM yöntemini ve ikinci veri seti kullandığımızda ilk veri setine göre daha doğru sınıflandırma haritası elde edilmiş ve aynı zamanda termal bant ve indekslerin kullanım etkisi görülmektedir.




Şekil 4.16. SVM yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.16’da yer alan 2020 yılına ait haritada görüldüğü gibi, SVM yöntemi ve ilk veri seti kullanılarak elde edilen haritada sınıflandırma tamamen yanlış yapılmıştır. Havzanın büyük bir kısmı sırasıyla yeşil, açık yeşil ve açık mavi renkte olan ormanlar, seyrek ormanlar ve mera olarak yanlışlıkla sınıflandırılmıştır.

Toprak sınıfı meralar sınıfında yer almaktadır ve haritada neredeyse hiç kahverengi renkteki toprak sınıfı görülmemektedir. Ayrıca, havzanın yapay yüzeyleri doğru bir şekilde sınıflandıramadığı için alanın doğu kesimlerindeki toprak sınıfı yanlışlıkla yapay yüzeyler sınıfına dahil edilmiş, yani SVM algoritması toprağı doğru bir şekilde ayıramamıştır.

Ayrıca, bu algoritma turuncu renkte gösterilen kuru tarım alanlarının sınıflandırılmasında hata yapmıştır. Bölgenin batı kesimlerindeki tüm kuru tarım arazileri yanlışlıkla mera ve toprak sınıflarına yerleştirilmiştir. Bu veri setinde, mavi renkteki su alanları ise büyük oranda doğru bir şekilde sınıflandırılmıştır.




Şekil 4.17. SVM yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.17’de yer alan 2020 yılına ait haritada görüldüğü gibi, ikinci veri seti ve SVM yöntemi kullanarak elde ettiğimiz haritada, sınıflandırma doğruluğu önemli ölçüde artmıştır. Örneğin, önceki haritada havzanın doğu yakasındaki yapay yüzeyler yanlış sınıflandırılmıştır, ancak bu hatalı pikseller ikinci veri seti kullanılarak düzeltilmiştir. Elde ettiğimiz harita bir önceki haritadan oldukça farklıdır; bu haritada yeşil ile işaretlenen ormanlar ve sarı ile işaretlenen yaş tarım arazileri doğru olarak sınıflandırılmıştır. Önceki haritadan farkı, kırmızıyla işaretlenen yapay yüzeylerin %95 doğrulukla, iyi bir şekilde sınıflandırılmasıdır. Ayrıca mavi renkli su alanları, açık yeşil renkli seyrek ormanlar ve turuncu renkli kuru tarım arazileri %95 doğrulukla ve başarılı bir şekilde sınıflandırılmıştır. Önceki haritada birçok hata bulunan toprak doğru sınıflandırılmış olup meralar ve yapay yüzeylerle çok az karışmıştır. SVM yöntemiyle açık mavi renkle işaretlenen meraların sınıflandırılmasında, toprak ve seyrek ormanlarla minimal etkileşim göstermiştir. Ancak ikinci veri seti kullanıldığımızda birinci veri setine göre daha doğru sınıflandırma haritası elde edilmiştir.

4.1.2.3. Gradyanla Güçlendirilmiş Ağaçlar


Gradyanla Güçlendirilmiş Ağaçlar, bir önceki ağacın hatalarını düzeltmek için yeni ağaçlar ekleyerek işlemi tekrar eden bir öğrenme yöntemidir. Her bir ağaç, önceki ağaçtan gelen hataları düzeltmeye odaklanarak modelin performansını artırmayı amaçlar. Bu yöntem, genellikle sınıflandırma ve regresyon problemlerinde etkili bir şekilde kullanılır ve geniş bir uygulama alanına sahiptir.

Gradyanla Güçlendirilmiş Ağaçlar yöntemi kullanılarak sınıflandırılmış görüntüler, 2000, 2009 ve 2020 yılları için iki veri seti kullanılarak aşağıda gösterilmiştir.




Şekil 4.18. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.18'de yer alan 2000 yılına ait haritasında görüldüğü gibi, ilk veri seti ve Gradyanla Güçlendirilmiş Ağaçlar yöntemini kullanarak yapılan sınıflandırmada, Kırmızı renkle işaretlenen yapay yüzeyleri, çalışma alanının güney ve kuzey kesimlerindeki toprak sınıfında hatalı olarak sınıflandırıldığı görülmektedir. Su alanlar, ormanlar ve yaş tarım alanları sırasıyla mavi, yeşil ve sarı renkte, doğru bir şekilde sınıflandırılmıştır. Ancak kuru tarım alanları birçok yerde toprak olarak sınıflandırılmıştır. Açık maviyle işaretlenmiş meralar ise doğru sınıflandırılmış ancak bazı yerlerde seyrek ormanlarla karışmıştır. Toprak sınıfı yanlış sınıflandırılmıştır.



Şekil 4.19. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)


Şekil 4.19'da yer alan 2000 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve Gradyanla Güçlendirilmiş Ağaçlar yöntemini kullanarak yapılan sınıflandırmada, yeşil renkle gösterilen ormanlar ve sarı renkle gösterilen yaş tarım alanları doğru şekilde sınıflandırılmıştır. Açık mavi renkle işaretlenmiş meraları %95'in üzerinde bir doğrulukla sınıflandırılmıştır. Sırasıyla mavi, açık yeşil ve kahverengi renklerle gösterilen su alanları, seyrek ormanlar ve toprak için seçilen test örnekleri %85'in üzerinde doğrulukla sınıflandırılmıştır. Turuncu renkle gösterilen kuru tarım alanları diğer sınıflara göre daha az doğrulukla sınıflandırılmıştır. Dolayısıyla test edilen örneklerin %30'u toprak sınıfında sınıflandırılmış ve sınıflandırmadaki bu hata havzanın kuzeybatısında daha sık gözlemlenmiştir. Kuru tarım alanları ve toprak sınıfları arasındaki etkileşim, bu alanların büyük benzerliğinden kaynaklanabilir. Çalışma alanının güney ve kuzey kesimlerinde kırmızı renkle işaretlenen yapay yüzeyler, %20 oranında yanlışlıkla toprak sınıfında görülmektedir. Buna rağmen ikinci veri seti kullanıldığında, ilk veri setine göre daha doğru bir sınıflandırma haritası elde edilmiştir.



Şekil 4.20. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)


Şekil 4.20’de yer alan 2009 yılına ait haritada görüldüğü gibi, ilk veri seti ve Gradyanla Güçlendirilmiş Ağaçlar yöntemiyle yapılan sınıflandırmada, yeşil renki ile gösterilen ormanlar, sarı renki ile gösterilen yaş tarım alanları ve mavi renkli su alanları doğru şekilde sınıflandırılmıştır. Kırmızı renkle işaretlenen yapay yüzeyleri nispeten iyi bir doğrulukla sınıflandırılmıştır. Ancak çalışma alanının kuzey bölgelerinde dağların beyaz toprağını madenlerden ayırmada hata yapılmıştır. Aynı hata çalışma alanının güneyinde ve doğusunda da görülmektedir. Seyrek orman sınıfı iyi sınıflandırılmıştır; ancak test örneklerinden bazıları beklendiği gibi orman sınıfına müdahale etmiştir.

Kahverengi renkte toprak sınıfına ait eğitim örneklerinin bir kısmının mera sınıfına, bir kısmının yapay yüzeyler sınıfına yanlış yerleştirilmesi görülmektedir. Haritada görüldüğü gibi, ilk veri setini kullandığımızda turuncu renkle işaretlenen kuru tarım alanları birçok yerde toprak ve mera olarak sınıflandırılmış ve sınılandırma doğruluğunu azaltmıştır. Açık mavi renkle işaretlenen meraların bazı yerlerinde seyrek ormanlara karışmış ve önemli ölçüde toprakla karışmıştır. Bu durum, meraların seyrek orman ve toprak sınıflarından ayırt edilmesinin zor olmasından kaynaklanmaktadır.



Şekil 4.21. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)


Şekil 4.21'de yer alan 2009 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve Gradyanla Güçlendirilmiş Ağaçlar yöntemini kullanarak yapılan sınıflandırmada, sırasıyla mavi, yeşil ve sarı renklerle işaretlenen su yüzeyleri, ormanlar ve yaş tarım alanları yüksek doğrulukla sınıflandırılmış ve diğer sınıflarla hiçbir etkileşime girmemiştir. İkinci veri setinde toprak %85'in üzerinde bir doğrulukla sınıflandırılmıştır. Açık mavi renkli meralar, toprak sınıfı ile %20 oranında, seyrek orman sınıfı ile ise %5 oranında karışmıştır. Bu durum, görüntülerin düşük çözünürlüğe sahip olmasından kaynaklanmaktadır. Turuncu renkle gösterilen kuru tarım alanlarına ait test örneklerin %80'i doğru sınıflandırılmış ve %15'i toprak sınıfında, %5'i ise mera sınıfında sınıflandırılmış ve sınıflandırmadaki bu hata havzanın kuzeybatısında gözlenmiştir. Açık yeşil ile gösterilen seyrek ormanlar, sınıflandırmada yaş tarım alanları ve orman sınıflarıyla az bir kısımlarda örtüşmektedir. Yapay yüzeyler ise ilk veri setine göre yüksek doğrulukla sınıflandırılmış ve ilk veri setindeki hatalar bu veri setinde telafi edilerek sınıflandırma doğruluğu arttırılmıştır. İkinci veri seti kullanıldığımızda, birinci veri setine göre daha doğru sınıflandırma haritası elde edilmiştir.



Şekil 4.22. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.22’de yer alan 2020 yılına ait haritada görüldüğü gibi ilk veri seti ve Gradyanla Güçlendirilmiş Ağaçlar yöntemiyle yapılan sınıflandırmada, sırasıyla turuncu, yeşil ve sarı renklerle işaretlenen kuru tarım alanları, ormanlar ve yaş tarım alanları yüksek doğrulukla sınıflandırılmıştır. Açık yeşil seyrek ormanlar iyi bir doğrulukla sınıflandırılmış, ancak bazı yerlerde meralar sınıfı ile müdahaleler vardır. Mavi renkli su alanları iyi bir doğrulukla sınıflandırılmış, ancak sınırlı alanlarda seyrek ormanlara müdahale etmiştir. Kırmızı renkle işaretlenen yapay yüzeyler nispeten iyi bir doğrulukla sınıflandırılmış ancak çalışma alanının kuzey ve doğu bölgelerinde, toprağın yapay yüzeylerden ayrılmasında az hata yapmıştır.

Kahverengi renkli toprak sınıfına ait eğitim örneklerinin bir kısmının meralar sınıfına, bir kısmının yapay yüzeyler sınıfına, bir kısmının ise kuru tarım alanları sınıfına yanlış yerleşerek sınıflandırma doğruluğu düşmüştür. Haritada gördüğünüz gibi, ilk veri setini kullandığımızda açık mavi meralar birçok yerde toprak olarak sınıflandırılmış ve aynı zamanda kuru tarım alanlarına müdahale ederek sınıflandırma doğruluğunu düşürmüştür. Bunun nedeni meraları, tarım alanı ve topraktan ayırmanın zor olmasıdır.




Şekil 4.23. Gradyanla güçlendirilmiş ağaçlar yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.23'te yer alan 2020 yılına ait haritada görüldüğü gibi, Gradyanla Güçlendirilmiş Ağaçlar yöntemi ve ikinci veri seti kullanıldığımızda, yanlışlıkla şekil 4.22'de yapay yüzeyleri sınıflandırılmış pikseller ortadan kaldırılmaktadır, bu da yapay yüzeylerin sınıflandırmasını iyileştirmiştir. Yeşil ve sarı renkle gösterilen ormanlar ve yaş tarım alanları yüksek doğrulukla sınıflandırılmıştır. Bu yöntem, sırasıyla mavi ve açık yeşil renklerle işaretlenmiş su ve seyrek ormanlarını %95'in üzerinde bir doğrulukla sınıflandırmıştır. Kırmızı renkli yapay yüzeyler %95 doğrulukla ilk veri setine göre başarılı bir şekilde sınıflandırılmıştır. Turuncu renkli kuru tarım alanları %90'lık bir doğrulukla sınıflandırılmıştır. Toprak sınıfı %80'lik bir doğrulukla sınıflandırılmış ancak bazen meralar, kuru tarım arazileri ve yapay yüzeyler sınıflarıyla örtüşmekte olup, sınıflar arasındaki benzerlik nedeniyle bunlar göz ardı edilebilir. Son olarak açık mavi renkli mera sınıfı düşük doğrulukla sınıflandırılmış, dolayısıyla %20'si seyrek orman sınıfına, %10'u toprak sınıfına, %5'i ise kuru tarım sınıfına yerleştirilmiştir. Buna rağmen ikinci veri seti kullanıldığımızda ilk veri setine göre çok daha doğru sınıflandırma haritası elde edilmiştir.


4.1.2.4. Sınıflandırma ve Regresyon Ağaçları (Cart)

CART, bir sınıflandırma ve regresyon ağacı algoritmasıdır. Bu yöntem, hiyerarşik karar ağaçları çerçevesine dayanır ve en basit ikili sınıflandırıcılardan biridir. CART sınıflandırma kararlarının, çok katmanlı sinir ağlarına kıyasla daha anlaşılır ve yorumlanabilir olmasıdır (Mather & Tso, 2016). Cart yöntemi kullanılarak sınıflandırılmış görüntüler, 2000, 2009 ve 2020 yılları için iki veri seti kullanılarak aşağıda gösterilmiştir.




Şekil 4.24. CART yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.24'te yer alan 2000 yılına ait haritasında görüldüğü gibi, ilk veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, Ormanlar, yaş tarım alanlar ve su alanları sırasıyla yeşil, sarı ve mavi renklerle doğru sınıflandırılmıştır. Kırmızı renkteki yapay yüzeyler, çalışma alanının farklı yerlerinde toprak sınıfına müdahale etmektedir. Açık yeşil renkteki seyrek ormanlar, sınıflandırmada orman ve meralara müdahale etmektedir. Turuncu renkteki kuru tarım alanları birçok yerde toprak, mera ve yaş tarım alanı olarak sınıflandırılmıştır. Açık mavi renkli meralar birçok yerde seyrek orman olarak sınıflandırılmıştır. Kahverengi renkli toprak, mera ve seyrek orman olarak sınıflandırılmıştır.




Şekil 4.25. CART yöntemiyle 2000 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.25'te yer alan 2000 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, bu algoritma diğer algoritmalarla göre zayıf performans göstermiştir. Çalışma alanının kuzey ve dağlık kesimlerinde yeşil renkle gösterilen ormanlar yanlışlıkla su olarak sınıflandırılmıştır. Bu hata bölgenin orta kesimlerinde mevcut, sarı renkli yaş tarım arazileri yanlış bir şekilde su sınıfına yerleştirilmiştir. Mavi renkle işaretlenen su alanlarının sınıflandırması %85 doğrulukla gerçekleştirilmiştir. Açık mavi renkle işaretlenen meraların sınıflandırması ise %90 doğrulukla gerçekleştirilmiştir. Kırmızıyla işaretlenen yapay yüzeyler, alanın farklı yerlerindeki toprak sınıfına müdahale etmiş ve ikinci veri setinin kullanılmasına rağmen sınıflandırmanın doğruluğu değişmemiştir. Turuncu renkteki kuru tarım alanları %75 doğrulukla sınıflandırılmıştır. Kahverengi toprağın %75 doğrulukla sınıflandırılmış ve sadece meralara ve seyrek ormanlara müdahale edilmiştir. Seyrek ormanlar %85 doğrulukla sınıflandırılmış ancak ormanlar ve yaş tarım alanlarına çok az müdahale edilmiştir. İkinci veri seti kullanıldığında elde edilen sınıflandırma haritası ile ilk veri seti ile elde edilen harita arasında çok belirgin bir fark görünmemiştir.



Şekil 4.26. CART yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.26'da yer alan 2009 yılına ait haritasında görüldüğü gibi, ilk veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, ormanlar ve yaş tarım alanlar sırasıyla yeşil ve sarı renklerle doğru şekilde sınıflandırılmıştır. Mavi renkle işaretlenen su alanları doğru bir şekilde tespit edilmiş ve diğer sınıflara müdahale etmemiştir. Kırmızı renkle işaretlenen yapay yüzeyler nispeten iyi bir doğrulukla sınıflandırılmıştır ancak çalışma alanının kuzey ve doğu bölgelerinde, toprağın (dağların) yapay yüzeylerden (madenlerden) ayrılmasında hata yapmıştır. Açık yeşil renkle işaretlenen seyrek ormanlar iyi bir doğrulukla sınıflandırılmış, ancak orman ve yaş tarım alanlarına çok az karışmıştır. Turuncu renkle işaretlenen kuru tarım alanları birçok yerde toprak olarak sınıflandırılmış ve meralara müdahale edilerek sınıflandırma doğruluğu azaltmıştır. Açık mavi renkle işaretlenen meralar birçok sınıflandırma hatası içermekte olup, çoğu yerde toprak ve seyrek ormanlarla karışmıştır. Bu veri setinde ve CART yöntemi kullanılarak kahverengi renkli toprak sınıflandırmada hata yapılmış ve çok sayıda piksel yanlışlıkla yapay yüzeyler sınıfına, bir kısmı de meralar sınıfına yerleştirilmiştir.




Şekil 4.27. CART yöntemiyle 2009 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.27'de yer alan 2009 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, bu algoritma diğer algoritmalara göre daha zayıf performans göstermiştir. Yeşil renkle gösterilen ormanlar iyi doğrulukla sınıflandırılmış ancak çalışma alanının kuzey alanlarının sınırlı kısımlarında hatalı bir şekilde su olarak sınıflandırılmıştır. Sarı renkli yaş tarım arazileri doğru olarak sınıflandırılmıştır. Mavi renkle işaretlenen su alanlarının sınıflandırması yüksek doğrulukla yapılmıştır. Kırmızı renkle işaretlenen yapay yüzeyler, ikinci veri seti kullanılarak %95'in üzerinde bir doğrulukla sınıflandırılmıştır.

Turuncu renkle işaretlenen kuru tarım arazileri %70 doğrulukla sınıflandırılmış, ancak havzanın farklı yerlerinde toprak ve meraya müdahale edilmiştir. Toprağın sınıflandırması %70 doğrulukla gerçekleştirilmiş, ancak karışık piksellerin varlığı nedeniyle sadece meralar, seyrek ormanlar ve yapay yüzeylerle etkileşime girmiştir.


Açık yeşil olarak işaretlenen seyrek ormanlar düşük doğrulukla sınıflandırılmış ve bu sınıfa ait test örneklerinin yarısı yaş tarım sınıfında yer almaktadır. Açık mavi renkteki meralar %70 doğrulukla sınıflandırılmıştır.



Şekil 4.28. CART yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 1)

Şekil 4.28'de yer alan 2020 yılına ait haritasında görüldüğü gibi, ilk veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, mavi renkle işaretlenen su alanları doğru bir şekilde tespit edilmiştir. CART yöntemiyle ormanlar ve yaş tarım alanları sırasıyla yeşil ve sarı renkte doğru şekilde sınıflandırılmıştır. Kırmızı renkle işaretlenen yapay yüzeyler, çalışma alanının doğu ve kuzey kesimlerinde, yani kırsal alanlar ve madenleri kapsayan bölgelerde, toprak sınıfında yanlışlıkla yerleştirilmiştir. Bunun nedeni, kırsal alanlarda toprağı, binalardan ayırmanın ve madenleri topraktan ayırmanın zor olmasıdır.

Turuncu renkle işaretlenen kuru tarım alanları iyi bir doğrulukla sınıflandırılmıştır. Açık yeşil renkle işaretlenmiş seyrek ormanlar genellikle doğru sınıflandırılmış, ancak bazı yerlerde meralar ve ormanlarla karışmıştır. Bu yöntem ve ilk veri seti kullanarak toprak sınıfını sınıflandırırken hata yapmış ve bazı noktalar meralar sınıfına, bazıları seyrek ormanlar sınıfına, bazıları ise yapay yüzeyler sınıfına yanlış yerleştirilmiştir. Havzanın orta kesimlerinde açık mavi renkle işaretlenen meralar, toprak ve seyrek ormanlarla etkileşime girmiş ve sınıflandırma doğruluğunu azaltmıştır.



Şekil 4.29. CART yöntemiyle 2020 tarihli sınıflandırılmış görüntü (veri seti 2)

Şekil 4.29'da yer alan 2020 yılına ait haritasında görüldüğü gibi, ikinci veri seti ve CART yöntemini kullanarak yapılan sınıflandırmada, yeşil renkle gösterilen ormanlar yüksek doğrulukla sınıflandırılmıştır. Ayrıca sarı renkle gösterilen yaş tarım alanları %95 doğrulukla sınıflandırılmıştır. Mavi renkte olan su alanları %95'in üzerinde bir doğrulukla sınıflandırılmıştır. Sırasıyla açık yeşil ve turuncu renklerle gösterilen seyrek orman ve kuru tarım alanları için seçilen test örnekleri %90'ın üzerinde bir doğrulukla sınıflandırılmıştır. Kırmızı renkle işaretlenen yapay yüzeyler %95'in üzerinde bir sınıflandırma doğruluğuna ulaşmıştır. Bu sonuç ilk veri setine göre önemli iyileşmeyi temsil etmektedir.

Havzanın farklı yerlerinde bulunan kahverengi renkteki toprak, yanlışlıkla kuru tarım alanları sınıfına yerleştirilmiş ve bu durum haritada açıkça görülmektedir. Ayrıca toprak sınıfı, meralar ve yaş tarım alanlar sınıfına müdahale etmiştir. Bu veri setinde meralar diğer sınıflara göre daha az doğrulukla açık mavi olarak sınıflandırılmış, toprak ve seyrek ormanlara birçok müdahalede bulunmaktadır. Ancak ikinci veri seti kullanıldığında termal bant ve indekslerin kullanılmasının, pozitif etkisi görülmektedir.

4.2. Araştırma Sonuçları

Bu bölüm, tezin ana sorularına cevap verirken, hipotezlerin doğruluğunu veya yanlışlığını ortaya çıkarmaktadır. Ayrıca analiz ettiğimiz verilere dayanarak, tezin amaçının ne ölçüde gerçekleştirildiğini, hangi sonuçların elde edildiğini ve bu sonuçların ne anlama geldiğini açıklamaktadır.

4.2.1. Sınıflandırma sonuçlarının doğruluk değerlendirmesi

Sınıflandırma sonuçlarının doğruluğu, sınıflandırma yöntemlerinin etkinliğini değerlendirmek için önemli bir ölçüttür. Doğru sınıflandırma sonuçları, doğru arazi kullanım kararları almak için gereklidir. Sınıflandırma sonuçlarının doğruluğunu değerlendirmek için genellikle üç ölçüt kullanılır: genel doğruluk, Kappa katsayısı ve hata matrisi.

4.2.1.1. Genel doğruluk

Genel doğruluk, bir sınıflandırma yönteminin ne kadar doğru sonuçlar verdiğini ölçen bir kriterdir. Bu kriter, bir uydu görüntüsü üzerinde yapılan arazi kullanımı sınıflandırması gibi birçok uygulamada önemlidir. Genel doğruluk, sınıflandırma sonuçlarının gerçek duruma ne kadar yakın olduğunu gösterir. Yüksek bir genel doğruluk, sınıflandırma sonuçlarının gerçek duruma daha yakın olduğunu gösterirken, düşük bir genel doğruluk sınıflandırma sonuçlarının gerçek duruma daha uzak olduğunu gösterir. Bu nedenle, sınıflandırma yöntemleri seçilirken genel doğruluk kriteri dikkate alınmalı ve en yüksek doğruluğu sağlayacak yöntemler tercih edilmelidir. Ayrıca, genel doğruluk değerlendirmesi için uygun bir doğruluk ölçütü seçilmesi ve doğruluk değerlendirmesinin doğru bir şekilde yapılması da önemlidir. Örneğin, Kappa katsayısı ve hata matrisi gibi ölçütler kullanılabilir (Alberg et al., 2004).

Genel doğruluk, sınıflandırma sonuçlarının doğruluğunu belirlemek için kullanılan en yaygın ölçüttür. Genel doğruluk, sınıflandırma sonuçlarının doğru olarak sınıflandırılan piksel sayısının, toplam piksel sayısına oranı olarak hesaplanır. Ayrıca Sınıflandırıcı tarafından doğru bir şekilde sınıflandırılan test verilerinin yüzdesini ifade eder. Genel doğruluk, sınıflandırma sonuçlarının ne kadar doğru olduğunu gösterir, ancak sınıflandırma sonuçlarında dengesiz sınıf dağılımı varsa yanıltıcı olabilir. Bu nedenle, sınıflandırma sonuçlarını daha kapsamlı bir şekilde değerlendirmek için diğer ölçütlerle birlikte kullanılması tavsiye edilir (Alberg et al., 2004). Tablo 4.1'de kullanılan yöntemlerin genel doğruluk değerleri açıklanmaktadır.

Tablo 4.1. Genel doğruluk değeri sınıflandırma yöntemlerine göre (veri seti 1 ve 2)

Sınıflandırma yöntemleri	Yıl	Genel doğruluk	
		Veri seti 1	Veri seti 2
Gradyanla güçlendirilmiş ağaçlar	2000	83.75	87.5
	2009	86.88	87.5
	2020	86.88	90
Destek Vektör Makinesi	2000	63.75	84.38
	2009	60	86.25
	2020	73.13	93.75
Rastgele Orman	2000	85	89.38
	2009	89.38	91.88
	2020	87.5	90.62
CART	2000	78.13	80.63
	2009	81.63	80
	2020	84.38	85

4.2.1.2. Kappa katsayısı

Kappa (K) katsayısı, sınıflandırmanın doğruluğunu ölçmek için kullanılan bir istatistiksel ölçüdür. Kappa katsayısı, iki gözlemcinin aynı ölçütü kullanarak farklı sonuçlar elde etme olasılığına karşı düzeltilmiş bir güvenilirlik ölçüsüdür. Sınıflandırmanın doğruluğunu ölçmek için kullanılan kappa katsayısı, diğer yöntemlerden daha güvenilir bir ölçüdür çünkü rastlantısal bir eşleşmeyi düzeltir. Sınıflandırma sonrasında oluşan sınıfların doğruluğunu belirlemek için doğruluk analizi yapmak önemlidir. Bu analiz, piksel değerlerinin referans kabul edilen haritalar veya arazi hakkında kesin bilgi veren bir kaynakla istatistiksel olarak karşılaştırılarak yapılır (McGrath, 2010).

Analizde, kullanıcı belirli noktalara ait sınıfların gerçek değerlerini girer ve bir hata matrisi oluşturulur. Bu matris [sınıf sayısı]x[sınıf sayısı] boyutlarındadır.

Sınıflandırılmış uydu görüntülerinin doğruluğunu belirlemek için iki farklı yöntem yaygın olarak kullanılmaktadır. Bunlardan ilki Chi-Kare (X^2) testi ile hatalı sınıflandırılan piksellerin belirlenmesidir. Diğeri ise hata matrisi ve Kappa (K) Katsayısı ile doğruluk analizidir. Kappa (K) Katsayısı, sınıflandırmanın doğruluğunu ağırlıklı olarak hesaplayan bir istatistiksel ölçüdür. Hata matrisinin satır/sütun toplamaları ve köşegeni üzerindeki

elemanlar kullanılarak elde edilir (Vieira et al., 2010). Bulunan Kappa(K) katsayısı değeri (Vieira et al., 2010);

- Kappa katsayısı 0.81-1 arasında ise, mükemmel uyum vardır
- Kappa katsayısı 0.61-0.80 arasında ise, iyi uyum vardır
- Kappa katsayısı 0.41-0.60 arasında ise, orta düzeyde uyum vardır
- Kappa katsayısı 0.21-0.40 arasında ise, zayıf uyum vardır
- Kappa katsayısı 0.00-0.20 arasında ise, uyumsuzluk vardır.

Tablo 4.2'de kullanılan yöntemlerin Kappa katsayısı değeri açıklanmaktadır.

Tablo 4.2. Kappa katsayısının değeri sınıflandırma yöntemlerine göre (veri seti 1 ve 2)

Sınıflandırma yöntemleri	Yıl	Kappa katsayısı	
		Veri seti 1	Veri seti 2
Gradyanla güçlendirilmiş ağaçlar	2000	0.81	0.86
	2009	0.85	0.86
	2020	0.85	0.89
Destek Vektör Makinesi	2000	0.59	0.82
	2009	0.54	0.84
	2020	0.69	0.93
Rastgele Orman	2000	0.83	0.88
	2009	0.88	0.91
	2020	0.86	0.89
CART	2000	0.75	0.78
	2009	0.78	0.77
	2020	0.82	0.83

4.2.1.3. Hata matrisi

Hata matrisi, sınıflandırma yöntemlerinin performansının değerlendirilmesinde önemli bir araçtır ve sınıflandırma sonuçlarının doğruluğunu daha ayrıntılı bir şekilde analiz etmeyi sağlar. Hata matrisi, sınıflandırma sonuçları ile gerçek durum arasındaki farkları gösterir ve sınıflandırma yönteminin hangi sınıfları ne kadar doğru veya yanlış sınıflandırdığını belirler. Hata matrisi, gerçek sınıf ve tahmin edilen sınıf arasındaki ilişkiyi gösteren bir tablodur. Tabloda, sınıflar gerçek ve tahmin edilen sınıflar olmak üzere iki eksen üzerinde yer alır. Tablonun köşegeni, doğru sınıflandırılan örneklerin

sayısını gösterirken, köşegen dışındaki hücreler yanlış sınıflandırılan örneklerin sayısını gösterir. Hata matrisi, sınıflandırma sonuçlarının doğruluğunu değerlendirmek için kullanılan birçok ölçütün hesaplanmasına olanak sağlar (Oort, 2007).

Hata matrisi 2000, 2009 ve 2020 yıllarına ve ilk veri setine ait her dört yöntem için aşağıda gösterilmiştir.

- 2000 tarihli Rastgele Orman, SVM, CART ve Gradyanla Güçlendirilmiş Ağaçlar yöntemlerine ait hata matrisleri:

2000 yılına ait Rastgele Orman yönteminin hata matrisi Tablo 4.3'te gösterilmektedir.

Tablo 4.3. 2000 tarihli Rastgele Orman yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrak Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	16	0	0	4	0	0	20
Su Yüzeyleri	1	2	0	17	0	0	0	0	20
Seyrak Ormanlar	1	0	0	0	18	0	0	1	20
Toprak	0	0	0	0	1	17	0	2	20
Kuru Tarım Alanları	0	0	0	0	0	5	15	0	20
Meralar	0	0	0	0	1	0	0	19	20
Toplam	22	22	16	17	20	26	15	22	160

Tablo 4.3'ten anlaşılabacağı gibi, Rastgele Orman algoritmasının hata matrisine göre, ormanlar ve yaş tarım alanları için seçilen test örneklerinin doğru sınıfta olduğu görülmektedir. Yapay yüzeylere ait test örneklerin %80'i doğru şekilde sınıflandırılmış, geri kalanı ise toprak sınıfı olarak sınıflandırılmıştır. Su alanları %85 doğrulukla sınıflandırılmış olup, örneklerin %5'i orman sınıfında, %10'u ise yaş tarım alan sınıfındadır. Seyrek ormanların 20 test örneğinden 18'i bu sınıfta doğru şekilde yerleştirilmiştir. Toprak sınıfına ait 17 test örneklerin doğru şekilde sınıflandırılmıştır. Bu algoritmada kuru tarım alanı sınıfında, 20 test örneğinden sadece 15 tanesi doğru

sınıfa yerleştirilmiştir. Mera sınıfı yüksek doğruluk oranına sahip olup ve örneklerin %95'i doğru şekilde sınıflandırılmıştır.

Bu algoritmada yanlış sınıflandırılan test numunelerinin çoğu toprak sınıfına yerleştirilmiştir. Algoritma genel olarak sınıfların sınıflandırılmasında iyi performans göstermiş ve sadece yapay yüzeyler ve kuru tarım alanlarının sınıflandırılmasında hata yapmıştır.

2000 yılına ait SVM yönteminin hata matrisi Tablo 4.4'te gösterilmektedir.

Tablo 4.4. 2000 tarihli SVM yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	15	0	0	4	1	0	20
Su Yüzeyleri	1	2	0	17	0	0	0	0	20
Seyrek Ormanlar	5	0	0	0	15	0	0	0	20
Toprak	0	0	0	0	1	16	0	3	20
Kuru Tarım Alanları	0	0	0	0	0	6	14	0	20
Meralar	0	0	0	0	2	0	0	18	20
Toplam	26	22	15	17	18	26	15	21	160

Tablo 4.4'ten anlaşılabacağı gibi, SVM algoritmasının hata matrisine göre, ormanlar ve yaş tarım alanları için seçilen test örneklerinin doğru sınıfta olduğu görülmektedir. Yapay yüzeylerine ait test numunelerinin %75'i doğru sınıflandırılmış, geri kalanı ise toprak sınıfı ve kuru tarım alanı olarak sınıflandırılmıştır. Su alanları %85 doğrulukla sınıflandırılmış, test örneklerin %5'i orman sınıfında, %10'u ise yaş tarım alanı sınıfındadır. Seyrek ormanlar için 20 test örneğinden 15'i doğru şekilde sınıflandırılmıştır. Toprak sınıfına ait 16 örnek doğru şekilde sınıflandırılmıştır. Kuru tarım alanı sınıfında ise 20 test örneğinden sadece 14'ü doğru şekilde sınıflandırılmıştır. Mera sınıfı örneklerin %90'ı doğru şekilde sınıflandırılmıştır.

SVM algoritması, Rasgele Orman algoritmasına göre daha zayıf bir performans göstermektedir. Dolayısıyla, sınıfların yalnızca yarısının doğru bir şekilde sınıflandırılmasında etkili olmaktadır.

2000 yılına ait Gradyanla Güçlendirilmiş Ağaçlar yönteminin hata matrisi Tablo 4.5'te gösterilmektedir.

Tablo 4.5. 2000 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrak Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	16	0	0	4	0	0	20
Su Yüzeyleri	1	2	0	17	0	0	0	0	20
Seyrak Ormanlar	1	0	0	0	18	0	0	1	20
Toprak	0	0	0	0	1	17	0	2	20
Kuru Tarım Alanları	0	0	0	0	0	6	14	0	20
Meralar	0	0	0	0	1	0	0	19	20
Toplam	22	22	16	17	20	27	14	22	160

Tablo 4.5'ten anlaşılacağı gibi, Gradyanla Güçlendirilmiş Ağaçlar algoritmasının hata matrisine göre, orman ve yaş tarım alanları için seçilen test örneklerinin doğru şekilde sınıflandırıldığı görülmektedir. Yapay yüzeylere ait test numunelerinin %80'i doğru, %20'si ise toprak sınıfında sınıflandırılmıştır. Su alanları %85 doğrulukla sınıflandırılmış olup, örneklerin %5'i orman sınıfında, %10'u ise yaş tarım alanı sınıfındadır. Seyrek ormanların 20 test örneğinden 18'i bu sınıfa doğru şekilde yerleştirilmiş; biri meralar sınıfında, biri ise ormanlar sınıfındadır. Toprak sınıfına ait 17 örnek doğru şekilde sınıflandırılmıştır. Bu algoritma ile sınıflandırmada, en fazla hata, kuru tarım arazisi sınıfında yapılmış; test örneklerinin sadece 14 tanesi doğru sınıflandırılmış ve geri kalanı ise toprak sınıfına yerleştirilmiştir. Önceki algoritmaların sınıflandırmasına benzer şekilde mera sınıfı örneklerin %90'ı doğru şekilde sınıflandırılmıştır.

Bu algoritmanın sonuçları, Rastgele Orman algoritmasına oldukça yakındır; yanlış sınıflandırılan test numunelerinin çoğu toprak sınıfına yerleştirilmiştir. Algoritma genel olarak sınıfların sınıflandırılmasında iyi performans göstermiş, ancak sadece yapay yüzeyler ve kuru tarım alanlarının sınıflandırılmasında hata yapmıştır. Bu hataların nedeni, yapay yüzeylerin ve kuru tarım alanlarının, toprak sınıfı ile büyük benzerlik göstermesinden dolayıdır.

2000 yılına ait CART yönteminin hata matrisi Tablo 4.6'da gösterilmektedir.

Tablo 4.6. 2000 tarihli CART yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	16	0	0	4	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	15	0	0	5	0	0	20
Su Yüzeyleri	1	2	0	17	0	0	0	0	20
Seyrek Ormanlar	6	0	0	0	13	0	0	1	20
Toprak	0	0	0	0	1	15	0	4	20
Kuru Tarım Alanları	0	0	2	0	0	3	15	0	20
Meralar	0	0	0	0	2	0	0	18	20
Toplam	23	22	17	21	16	23	15	23	160

Tablo 4.6'dan anlaşılabacağı gibi, CART algoritmasının hata matrisine göre, ormanlar için seçilen test örneklerinin %80'i doğru şekilde sınıflandırılmış, %20'sinin ise yanlışlıkla su sınıfına yerleştirildiği görülmektedir. Yaş tarım arazileri ise doğru şekilde sınıflandırılmıştır. Yapay yüzeylere ait test örneklerinin %75'i doğru şekilde sınıflandırılmış, %25'i ise yanlışlıkla toprak sınıfına yerleştirilmiştir. Su alanları %85 doğrulukla sınıflandırılmış; örneklerin %5'i orman sınıfında, %10'u ise yaş tarım alanı sınıfındadır. Bu durumun nedeni, bu sınıflardaki nemin varlığından kaynaklanmaktadır. Seyrek ormanlara ait 13 adet test örneği doğru şekilde bu sınıfa yerleştirilmiş, bir tanesi mera sınıfında ve 6 tanesi ise yanlışlıkla orman sınıfına dahil edilmiştir. Toprak sınıfından 15 test örneği doğru şekilde sınıflandırılmış, geri kalanlar ise meralara ve seyrek ormanlara yanlışlıkla yerleştirilmiştir. Kuru tarım arazileri sınıfında sadece 15 test örneği doğru olarak sınıflandırılmış, geri kalanlar ise toprak ve yapay yüzeyler sınıfına yanlışlıkla dahil edilmiştir. Mera sınıfı örneklerin %90'ı doğru şekilde sınıflandırılmıştır.

Diğer algoritmaların sınıflandırmasındaki hatalar bu algortmada da mevcuttur, ancak 2000 yılı için tüm algoritmalar ile elde edilen sonuçlardan farklı olarak, CART algoritması ormanlar ve seyrek ormanların sınıflandırılmasında daha zayıf bir performansa sahiptir.

- 2009 tarihli Rastgele Orman, SVM, CART ve Gradyanla güçlendirilmiş ağaçlar yöntemlerine ait hata matrisleri:

2009 yılına ait Rastgele Orman yönteminin hata matrisi Tablo 4.7’de gösterilmektedir.

Tablo 4.7. 2009 tarihli Rastgele Orman yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	19	0	1	0	0	0	20
Su Yüzeyleri	0	0	0	20	0	0	0	0	20
Seyrek Ormanlar	2	3	0	0	15	0	0	0	20
Toprak	0	0	0	0	0	19	0	1	20
Kuru Tarım Alanları	0	0	0	0	0	4	15	1	20
Meralar	0	0	0	0	0	2	0	18	20
Toplam	22	23	19	20	16	25	15	20	160

Tablo 4.7’den anlaşılabacağı gibi, Rastgele Orman algoritmasının hata matrisine göre, ormanlar, yaş tarım alanları ve su alanları için seçilen test örneklerinin doğru sınıfta olduğu görülmektedir. Yapay yüzeylere ait test örneklerinin %95’i doğru sınıflandırılmış ve sadece %5’i seyrek orman sınıfındadır. Seyrek ormanlara ait 20 test örneğinden 15’i doğru bir şekilde bu sınıfa yerleştirilirken, geri kalanlar ise ormanlar ve yaş tarım alanları sınıflarına yerleştirilmiştir. Toprak sınıfından 19 test örneği doğru bir şekilde sınıflandırılmış ve yüksek bir doğruluğa sahiptir. Kuru tarım arazisi sınıfında ise sadece 15 test örneği doğru şekilde sınıflandırılmış ve 5 tanesi toprak sınıfında yer almaktadır, yani algoritma bu sınıfı topraktan ayırt etmede zorlanmıştır. Meralar sınıfı yüksek doğrulukla sınıflandırılmış; örneklerin %90’ı doğru şekilde sınıflandırılmıştır.

Bu algoritmanın hata matrisine göre, yanlış sınıflandırılan test numunelerinin çoğu toprak sınıfına yerleştirilmiştir. Genel olarak, algoritma sınıfların sınıflandırılmasında başarılı olmuş, ancak seyrek ormanlar ve kuru tarım alanları sınıflandırmasında hata yapmıştır.

2009 yılına ait SVM yönteminin hata matrisi Tablo 4.8’de gösterilmektedir.

Tablo 4.8. 2009 tarihli SVM yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	15	0	0	2	3	0	20
Su Yüzeyleri	0	0	0	20	0	0	0	0	20
Seyrek Ormanlar	5	0	0	0	15	0	0	0	20
Toprak	0	0	0	0	0	18	0	2	20
Kuru Tarım Alanları	0	0	0	0	0	3	16	1	20
Meralar	0	1	0	0	2	3	0	14	20
Toplam	25	21	15	20	17	26	19	17	160

Tablo 4.8’den anlaşılabacağı gibi, SVM algoritmasının hata matrisine göre, ormanlar, yaş tarım alanları ve su alanları için seçilen test örneklerinin doğru sınıfta olduğu görülmektedir. Yapay yüzeylere ait test örneklerinin %75’i doğru sınıflandırılmış, geri kalanı ise toprak ve kuru tarım arazisi olarak sınıflandırılmıştır. Seyrek ormanlara ait test örneklerinin %75’i bu sınıfa doğru şekilde sınıflandırılmış, %25’i ise orman sınıfında yer almaktadır. Toprak sınıfına ait 20 test örneğinden 18’i doğru şekilde sınıflandırılmıştır. Mera sınıfına ait test örneklerinden sadece 14 tanesi doğru şekilde sınıflandırılmış, geri kalanlar ise toprak, seyrek orman ve yapay yüzeyler sınıflarına yerleştirilmiştir. Kuru tarım sınıfına ait test örneklerinden sadece 16 tanesi doğru şekilde sınıflandırılmış, geri kalanı ise toprak sınıfına yerleştirilmiştir.

SVM algoritması, Rastgele Orman algoritmasına benzer şekilde seyrek ormanların ve kuru tarım arazilerinin sınıflandırılmasında düşük performans göstermiştir. Rastgele Orman algoritması ile karşılaştırıldığında, SVM algoritmasının yapay yüzeylerin ve meraların sınıflandırılmasında daha zayıf bir performansa sahip olduğu görülmüştür. Rastgele Orman algoritmasının yapay yüzeyler ve meraların sınıflandırılmasında daha iyi sonuçlar göstermektedir.

2009 yılına ait Gradyanla Güçlendirilmiş Ağaçlar yönteminin hata matrisi Tablo 4.9’da gösterilmektedir.

Tablo 4.9. 2009 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	16	0	1	3	0	0	20
Su Yüzeyleri	0	0	0	20	0	0	0	0	20
Seyrek Ormanlar	2	2	0	0	16	0	0	0	20
Toprak	0	0	0	0	0	17	2	1	20
Kuru Tarım Alanları	0	0	0	0	0	3	16	1	20
Meralar	0	0	0	0	1	4	0	15	20
Toplam	22	22	16	20	18	27	18	17	160

Tablo 4.9’den anlaşılacağı gibi, Gradyanla Güçlendirilmiş Ağaçlar algoritmasının hata matrisine göre, ormanlar, yaş tarım alanları ve su alanları için seçilen test örneklerinin doğru şekilde sınıflandırıldığı görülmektedir. Yapay yüzeylere ait test örneklerinin %80’i doğru sınıflandırılmış, geri kalanı ise toprak ve seyrek orman olarak sınıflandırılmıştır. Seyrek ormanlara ait test örneklerinin %80’i bu sınıfa doğru şekilde sınıflandırılmış, geri kalanı ise orman ve yaş tarım alanı olarak sınıflandırılmıştır. Toprak sınıfına ait 17 test örneği doğru şekilde sınıflandırılmış, ancak bazıları meralar ve kuru tarım arazilerine yanlış yerleştirildiği görülmektedir. Mera sınıfına ait test örneklerinden sadece 15 tanesi doğru şekilde sınıflandırılmış, geri kalanı ise toprak ve seyrek orman sınıflarına yerleştirilmiştir. Kuru tarım arazi sınıfı %80 doğrulukla sınıflandırılmıştır.

Bu algoritmada yanlış sınıflandırılan test numunelerinin çoğu toprak sınıfına yerleştirilmiştir. Algoritma, meralar, yapay yüzeyler, seyrek ormanlar ve kuru tarım alanlarının sınıflandırılmasında düşük performans göstermektedir. Bu yöntem, SVM yöntemine göre iyi performans göstermiş, ancak Rastgele Orman yöntemine ait yapay yüzeyler ve meralar sınıflarına göre düşük performans göstermiştir.

2009 yılına ait CART yönteminin hata matrisi Tablo 4.10’da gösterilmektedir.

Tablo 4.10. 2009 tarihli CART yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	19	0	0	1	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	19	0	1	0	0	0	20
Su Yüzeyleri	0	0	0	20	0	0	0	0	20
Seyrek Ormanlar	1	10	1	0	8	0	0	0	20
Toprak	0	0	1	0	0	14	2	3	20
Kuru Tarım Alanları	0	0	0	0	0	5	14	1	20
Meralar	0	0	0	0	1	5	0	14	20
Toplam	20	30	21	21	10	24	16	18	160

Tablo 4.10'dan anlaşılabacağı gibi, CART algoritmasının hata matrisine göre, ormanlar için seçilen test örneklerinin %95'i doğru bir şekilde sınıflandırılmış, %5'i ise su sınıfına yerleştirilmiştir. Yaş tarım arazileri doğru şekilde sınıflandırılmıştır. Yapay yüzeylere ait test örneklerin %95'i doğru sınıflandırılmış, %5'i ise seyrek orman olarak sınıflandırılmıştır. Su alanları doğru şekilde sınıflandırılmıştır. Seyrek ormanlara ait 20 adet test örneğinin sadece 8'i bu sınıfa doğru şekilde yerleştirilmiş, örneklerinin geri kalanı ise yaş tarım alan olarak sınıflandırılmıştır. Ancak bu durum, algoritmanın seyrek orman sınıflandırmasındaki zayıflığını göstermektedir. Toprak sınıfına ait test örneklerinden sadece 14 tanesi doğru şekilde sınıflandırılmış, geri kalanı ise mera ve kuru tarım sınıflarına yerleştirilmiştir. Kuru tarım arazileri sınıfında sadece 14 tanesi doğru olarak sınıflandırılmıştır. Mera sınıfı %70 doğrulukla sınıflandırılmış, geri kalanı ise toprak ve seyrek orman sınıflarına yerleştirilmiştir.

Bu algoritma önceki üç yönteme göre daha zayıf bir performansa sahiptir. Örneğin, seyrek ormanların sınıflandırılmasında çok zayıf bir performans göstermiş, dolayısıyla test örneklerinin yarısından fazlası doğru sınıfa yerleştirilmemiştir.

Ayrıca, bu algoritma ile toprak, kuru tarım arazisi ve mera sınıflarının sınıflandırılmasında önceki üç yönteme göre daha zayıf bir performans sergilendiği gözlemlenmektedir. Algoritmanın hata matrisi, bu üç sınıfı doğru şekilde ayırt edemediğini ve sınıflandırmada sorunlar yaşadığını göstermektedir.

- 2020 tarihli Rastgele Orman, SVM, CART ve Gradyanla Güçlendirilmiş Ağaçlar yöntemlerine ait hata matrisleri:

2020 yılına ait Rastgele Orman yönteminin hata matrisi Tablo 4.11’de gösterilmektedir.

Tablo 4.11. 2020 tarihli Rastgele Orman yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	18	0	0	1	0	1	20
Su Yüzeyleri	0	0	0	19	1	0	0	0	20
Seyrek Ormanlar	0	0	0	0	19	0	0	1	20
Toprak	0	0	0	0	1	17	1	1	20
Kuru Tarım Alanları	0	0	1	0	0	0	11	0	20
Meralar	0	0	0	0	4	3	0	13	20
Toplam	20	20	19	19	25	21	20	16	160

Tablo 4.11’den anlaşılabacağı gibi, Rastgele Orman algoritmasının hata matrisine göre, ormanlar ve yaş tarım alanları için seçilen test örnekleri doğru şekilde sınıflandırılmıştır. Su alanları, seyrek ormanlar ve kuru tarım arazileri sınıflarına ait test örneklerinin %95’i doğru şekilde sınıflandırılmıştır. Yapay yüzeylere ait test numunelerinin %90’ı doğru sınıflandırılmış, bunların %5’i seyrek orman sınıfına, %5’i ise toprak sınıfına yerleştirilmiştir. Toprak sınıfına ait 20 örnekten 17’si doğru şekilde sınıflandırılmış, geri kalanı ise seyrek orman, kuru tarım arazi ve mera sınıflarına müdahale etmiştir.

Mera sınıfı, sınıflar arasında en düşük sınıflandırma doğruluğuna sahiptir; test örneklerinden sadece 13 tanesi doğru şekilde sınıflandırılmış, geri kalanı ise seyrek orman sınıfına yerleştirilmiştir. Ancak bunun nedeni mera sınıfı ile seyrek orman sınıfı arasındaki benzerliklerden dolayı olmaktadır.

Algoritma, bu yılın sınıflandırmasında, 2000 ve 2009 yılına nazaran iyi performans göstermiş ve bunun nedeni 2020 yılına ait Landsat görüntüsünün kaliteli olmasıdır.

2020 yılına ait SVM yönteminin hata matrisi Tablo 4.12’de gösterilmektedir.

Tablo 4.12. 2020 tarihli SVM yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	19	0	0	1	0	0	20
Su Yüzeyleri	0	0	0	19	1	0	0	0	20
Seyrek Ormanlar	0	0	0	0	19	0	0	1	20
Toprak	0	0	1	0	0	18	0	1	20
Kuru Tarım Alanları	0	0	0	0	0	1	19	0	20
Meralar	0	0	0	0	3	1	0	16	20
Toplam	20	20	20	19	23	21	19	18	160

Tablo 4.12’den anlaşılacağı gibi, SVM algoritmasının hata matrisine göre, ormanlar, yaş tarım alanları ve su alanları için seçilen test örnekleri doğru şekilde sınıflandırılmıştır. Yapay yüzeyler, su alanları, seyrek ormanlar ve kuru tarım arazileri sınıfları %95 doğrulukla sınıflandırılmıştır. Toprak sınıfına ait 20 örnekten 18’i doğru şekilde sınıflandırılmış, geri kalanı ise yapay yüzeyler ve mera olarak sınıflandırılmıştır.

Mera sınıfı, sınıflar arasında en düşük sınıflandırma doğruluğuna sahiptir; test örneklerinden sadece 16 tanesi doğru şekilde sınıflandırılmış, geri kalanı ise seyrek orman ve toprak sınıfına yerleştirilmiştir. Ancak bunun nedeni, mera sınıfı ile seyrek orman sınıfı arasındaki benzerliklerden dolayıdır.

Bu algoritmanın 2020 yılına ait hata matrisinin rakamlarını gözlemleyerek, SVM algoritmasının sınıflandırma doğruluğu, 2000 ve 2009 yıllarına göre yüksek olduğu anlaşılmaktadır.

SVM algoritması, 2020’de Rastgele Orman algoritmasından daha doğru sonuçlar elde etmiş ve bunun nedeni Landsat görüntüsünün çözünürlüğünün artmasıyla sınıflandırılmış haritanın doğruluğunun önemli ölçüde artmasıdır.

2020 yılına ait Gradyanla Güçlendirilmiş Ağaçlar yönteminin hata matrisi Tablo 4.13’te gösterilmektedir.

Tablo 4.13. 2020 tarihli Gradyanla güçlendirilmiş ağaçlar yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	0	20	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	19	0	0	1	0	0	20
Su Yüzeyleri	0	0	0	19	1	0	0	0	20
Seyrek Ormanlar	0	0	0	0	19	0	0	1	20
Toprak	0	0	2	0	0	16	1	1	20
Kuru Tarım Alanları	0	0	1	0	0	1	18	0	20
Meralar	0	0	0	0	4	2	1	13	20
Toplam	20	20	22	19	24	20	20	15	160

Tablo 4.13'ten anlaşılabileceği gibi, Gradyanla Güçlendirilmiş Ağaçlar algoritmasının hata matrisine göre, orman ve yaş tarım arazileri için seçilen test örneklerinin doğru şekilde sınıflandırıldığı görülmektedir. Yapay yüzeylere ait test örneklerin %95'i doğru şekilde sınıflandırılmış, geri kalanı ise toprak olarak sınıflandırılmıştır. Su alanlarına verilen 20 test örneklerinden 19'u doğru şekilde sınıflandırılmış ve sadece 1 test örneği seyrek ormanla yerleştirilmiştir. Seyrek ormana ait 20 test örneklerinden 19'u doğru olarak sınıflandırılmış, sadece bir tanesi mera olarak sınıflandırılmıştır. Toprak sınıfına ait örneklerin 16'sı doğru olarak sınıflandırılmış olup, geri kalanı ise mera, kuru tarım alanı ve yapay yüzey olarak sınıflandırılmıştır. Bu algoritmada örneklerin sınıflandırılmasında en fazla hata mera sınıfına aittir; bunlardan sadece 13 tanesi doğru sınıflandırılmış, geri kalanlar ise toprak ve seyrek orman sınıflarına yerleştirilmiştir.

Kuru tarım arazi sınıfı %90 doğrulukla sınıflandırılmıştır. Bu algoritmada yanlış sınıflandırılan test örneklerinin büyük bir kısmı seyrek orman sınıfına yerleşmektedir; 24 sayısı bu durumu göstermektedir. Bu algoritmanın sonuçları Rastgele Orman algoritmasının sonuçlarına benzemektedir.

2020 yılına ait CART yönteminin hata matrisi Tablo 4.14'te gösterilmektedir.

Tablo 4.14. 2020 tarihli CART yönteminin hata matrisi

Sınıflar	Ormanlar	Yaş Tarım Alanları	Yapay Yüzeyler	Su Yüzeyleri	Seyrek Ormanlar	Toprak	Kuru Tarım Alanları	Meralar	Toplam
Ormanlar	20	0	0	0	0	0	0	0	20
Yaş Tarım Alanları	1	19	0	0	0	0	0	0	20
Yapay Yüzeyler	0	0	19	0	0	1	0	0	20
Su Yüzeyleri	0	0	0	19	1	0	0	0	20
Seyrek Ormanlar	0	0	0	0	18	0	0	2	20
Toprak	0	0	1	0	1	11	6	1	20
Kuru Tarım Alanları	0	0	1	0	0	0	18	1	20
Meralar	0	0	0	0	4	4	0	12	20
Toplam	21	19	21	19	24	16	24	16	160

Tablo 4.14'ten anlaşılacağı gibi, CART algoritmasının hata matrisine göre, ormanlar için seçilen test örneklerinin %100 doğru sınıflandırıldığı görülmektedir. Yaş tarım arazileri, yapay yüzeyler ve su alanlarından oluşan test örneklerin %95'i doğru şekilde sınıflandırılmıştır. Seyrek ormanlara ait test örneklerinden 18 tanesi doğru olarak bu sınıfa, 2 tanesi ise mera sınıfına yerleştirilmiştir. Toprak sınıfına ait örneklerin 16'sı doğru olarak sınıflandırılmış, geri kalanı ise mera, kuru tarım alanı ve yapay yüzey olarak sınıflandırılmıştır. Mera sınıfı, sınıflar arasında en düşük sınıflandırma doğruluğuna sahiptir; sadece 12 test örneği doğru şekilde sınıflandırılmış, geri kalanı ise seyrek orman ve toprak sınıfına yerleşmektedir. Bunun nedeni, mera sınıfı ile seyrek orman sınıfı arasındaki benzerliklerden dolayı olmaktadır. Kuru tarım arazisi sınıfı %90 doğrulukla sınıflandırılmıştır. CART yöntemi, diğer yöntemlere göre zayıf bir performans göstermektedir.

4.2.2. Değişim analizi

Değişim analizi, belirli bir süre içinde bir bölgedeki arazi kullanımı değişiklikleri inceleyen bir uzaktan algılama yöntemidir. Bu yöntem, uydu görüntüleri kullanılarak gerçekleştirilir. Değişim analizi, farklı zamanlarda elde edilen uydu görüntüleri arasındaki farkları tespit ederek yapılmaktadır. Bu çalışmada her veri seti için sınıflandırma haritaları, her yöntemin hata matrisleri ve her yöntemin genel doğruluk ve Kappa katsayıları incelenmiştir. Sonuç olarak, Porsuk Havzası'ndaki değişiklikleri analiz etmek için Rasgele Orman ve Gradyanla Güçlendirilmiş Ağaçlar algoritmalarının en iyi

algoritmalar olduğu sonuuna varılmıştır. Bu iki yöntem ile her sınıfa ait hesaplanan alanlar aşğıdaki tablolarda görölmektedir.

4.2.2.1. Rastgele Orman

Rastgele Orman algoritması ile her yıl ve her sınıf için hesaplanan alanlar Tablo 4.15’ te gösterilmektedir.


Tablo 4.15. *Rastgele Orman algoritması ile her yıl ve sınıf için hesaplanan alanlar*

Sınıflar	2000		2009		2020	
	Alan (km ²)	Alan (%)	Alan (km ²)	Alan (%)	Alan (km ²)	Alan (%)
Ormanlar	1054.82	9.75	1481.82	13.69	2058.01	19.02
Yaş Tarım Alanları	450.73	4.16	462.95	4.28	615.44	5.69
Yapay Yüzeyler	150.96	1.39	201.10	1.86	251.98	2.33
Su Yüzeyleri	31.71	0.28	29.35	0.27	45.60	0.42
Seyrak Ormanlar	1520.39	14.05	2010.65	18.58	1572.49	14.53
Toprak	4018.38	37.13	2986.06	27.59	2352.20	21.74
Kuru Tarım Alanları	1866.12	17.24	2121.48	19.60	2003.64	18.52
Meralar	1729.69	15.98	1528.37	14.12	1921.55	17.76


Tablo 4.15'te gösterildiğı gibi, Porsuk Havzası'nı Rastgele Orman yöntemiyle sınıflandırdıktan sonra her sınıfın alanı hesaplanmıştır. 2000 yılında orman sınıfının alanı 1058,82 kilometrekare olup, çalışma alanının %9,75'ine denk gelmektedir. 2009 yılında bu sınıfın alanı 1481,82 kilometrekare iken, 2020 yılında 2058,01 kilometrekare olarak hesaplanmıştır. 2000 yılında kuru tarım alanı, yapay yüzeyler ve su alanları sırasıyla 450,73, 150,96 ve 31,71 kilometrekare, 2009 yılında sırasıyla 462,95, 201,10 ve 29,35 kilometrekare ve 2020 yılında ise sırasıyla 615,44, 251,98 ve 45,60 kilometrekare olarak hesaplanmıştır. Bu üç sınıfın alanları artış göstermiştir. 2000 yılında seyrek orman ve kuru tarım sınıflarının alanı sırasıyla 1520,39 ve 1866,12 kilometrekare iken, 2009 yılında her iki sınıfta alan artışı gözlenmiş ve bu sınıfların alanı sırasıyla 2010,65 ve 2121,48 kilometrekare olmuştur. 2020 yılında ise alanları sırasıyla 1572,49 ve 2003,64 kilometrekare olarak 2009'a göre düşüş yaşanmıştır.

Toprak sınıfının alanı 2000, 2009 ve 2020 yılları için sırasıyla 45018,38, 2986,06 ve 2352,20 kilometrekare olarak hesaplanmıştır. 2000, 2009 ve 2020 yılları için mera

alanı sırasıyla 1729,69, 1528,37 ve 1921,55 kilometrekare olarak hesaplanmıştır. Rastgele Orman algoritması ile her sınıf için hesaplanan alanın kilometrekaresi ve yüzdesi, sırasıyla Şekil 4.30 ve Şekil 4.31’de gösterilmektedir.



Şekil 4.30. Rastgele Orman algoritması ile her sınıf için hesaplanan alanlar (km²)



Şekil 4.31. Rastgele Orman algoritması ile her sınıf için hesaplanan alanlar (%)

4.2.2.2. Gradyanla Güçlendirilmiş Ağaçlar

Gradyanla Güçlendirilmiş Ağaçlar algoritması ile her yıl ve her sınıf için hesaplanan alanlar Tablo 4.16'da gösterilmektedir.


Tablo 4.16. Gradyanla güçlendirilmiş ağaçlar algoritması ile her yıl ve sınıf için hesaplanan alanlar

Sınıflar	2000		2009		2020	
	Alan (km ²)	Alan (%)	Alan (km ²)	Alan (%)	Alan (km ²)	Alan (%)
Ormanlar	1102.57	10.18	1371.05	12.66	2063.34	19.06
Yaş Tarım Alanları	412.18	3.80	496.74	4.59	601.45	5.55
Yapay Yüzeyler	180.31	1.66	207.20	1.91	246.10	2.27
Su Yüzeyleri	30.94	0.28	30.86	0.28	47.05	0.43
Seyrek Ormanlar	1483.11	13.70	2158.42	19.94	1769.76	16.35
Toprak	3969.90	36.68	2744.74	25.36	2198.82	20.32
Kuru Tarım Alanları	1944.99	17.97	2275.96	21.03	2122.89	19.61
Meralar	1697.76	15.68	1536.77	14.20	1771.45	16.37


Tablo 4.16'da gösterildiği gibi, Porsuk Havzası'nı Gradyanla Güçlendirilmiş Ağaçlar yöntemiyle sınıflandırdıktan sonra her sınıfın alanını hesaplanmıştır. 2000 yılında orman sınıfının alanı 1102,57 kilometrekare olup, çalışma alanının %10,18'ine denk gelmektedir. 2009 yılında bu sınıfın alanı 1371,05 kilometrekare iken, 2020 yılında 2063,34 kilometrekare olarak hesaplanmıştır. 2000 yılında kuru tarım alanları, yapay yüzeyler ve su alanları sırasıyla 412,18, 180,31 ve 30,94 kilometrekare, 2009 yılında sırasıyla 496,74, 207,20 ve 30,86 kilometrekare ve 2020 yılında ise sırasıyla 601,45, 246,10 ve 47,05 kilometrekare olarak hesaplanmıştır. Bu üç sınıfın alanları artış göstermiştir. 2000 yılında seyrek ormanlar ve kuru tarım sınıflarının alanı sırasıyla 1483,11 ve 1944,99 kilometrekare, 2009 yılında her iki sınıfta alan artışı görülmekte olup, bu sınıfların alanı sırasıyla 2158,42 ve 2275,96 kilometrekare hesaplanmıştır. 2020 yılında alanları sırasıyla 1769,76 ve 2122,89 kilometrekare olarak 2009'a göre düşüş yaşanmıştır.

Toprak sınıfının alanı 2000'den 2020'ye kadar sırasıyla 3969,90, 2744,74 ve 2198,82 kilometrekare olarak hesaplanmıştır. 2000, 2009 ve 2020 yılları için mera alanı

sırasıyla 1697,76, 1536,77 ve 1771,45 kilometrekare olarak hesaplanmıştır. Gradyanla Güçlendirilmiş Ağaçlar yöntemiyle her sınıf için hesaplanan alanın kilometre karesi ve yüzdesi sırasıyla Şekil 4.32 ve Şekil 4.33'te gösterilmektedir.



Şekil 4.32. Gradyanla güçlendirilmiş ağaçlar algoritması ile her sınıf için hesaplanan alanlar (km²)



Şekil 4.33. Gradyanla güçlendirilmiş ağaçlar algoritması ile her sınıf için hesaplanan alanlar (%)

4.2.2.3. Değişim analizin sonucu

Değişim analizi sonucunda, Porsuk Havzası'ndaki arazi kullanımının sınıflandırılması için en uygun yöntem olarak Rastgele Orman yöntemi seçilmiştir. Bu yöntem, diğer yöntemlere göre daha iyi sonuçlar vermiş ve arazi kullanımı sınıflandırmasında daha etkili bir yöntem olarak değerlendirilmiştir.

Ayrıca, Rastgele Orman yöntemi kullanılarak yapılan arazi kullanımı sınıflandırması sonucunda elde edilen veriler, diğer yöntemlere göre daha doğru ve ayrıntılı bilgiler sağlamaktadır. Bu nedenle, Rastgele Orman yöntemi Porsuk Havzası'ndaki arazi kullanımı değişikliklerinin analizi için en uygun yöntem olarak seçilmiştir. Bu yöntem kullanılarak yapılan arazi kullanımı değişikliği analizi sonucunda, 2000 yılından 2020 yılına kadar Porsuk havzası'ndaki arazi kullanımında önemli değişiklikler tespit edilmiştir. Bu değişiklikler arasında tarım alanlarının artması, yerleşim alanlarının artması ve ormanlık alanların artması gibi önemli değişimler yer almaktadır (Bkz. Tablo 4.17, Tablo 4.18).

Tablo 4.17. Değişim analizin sonucu (km²)

Sınıflar	2000-2009	2009-2020	2000-2020
Ormanlar	427.00	576.19	1003.19
Yaş Tarım Alanları	12.23	152.49	164.72
Yapay Yüzeyler	50.14	50.88	101.02
Su Yüzeyleri	-1.36	16.25	14.90
Seyrak Ormanlar	490.26	-438.16	52.10
Toprak	-1032.32	-633.86	-1666.18
Kuru Tarım Alanları	255.36	-117.84	137.52
Meralar	-201.32	393.17	191.86

Tablo 4.18. Değişim analizin sonucu (%)

Sınıflar	2000-2009	2009-2020	2000-2020
Ormanlar	3.95	5.33	9.27
Yaş Tarım Alanları	0.11	1.41	1.52
Yapay Yüzeyler	0.46	0.47	0.93
Su Yüzeyleri	-0.01	0.15	0.14
Seyrak Ormanlar	4.53	-4.05	0.48
Toprak	-9.54	-5.86	-15.39
Kuru Tarım Alanları	2.36	-1.09	1.27
Meralar	-1.86	3.63	1.77

Tablo 4.19'da gösterildiği gibi, Porsuk Havzası'nda, 2000'den 2009'a kadar olan 9 yıllık sürede ormanların alanı 427 kilometrekare artmıştır. 2009'dan 2020'ye bu miktar 576,19 kilometrekareye ulaşmış ve toplamda 2000'den 2020 yılına kadar incelenen dönemde 1003,19 kilometrekareye ulaşmıştır. Bu önemli bir artışı göstermektedir.

Yaş tarım arazileri 2000'den 2009'a kadar, 12,23 kilometrekare artış göstermiş, ancak 2009'dan 2020'ye kadar bu miktar önemli ölçüde artarak 152,49 kilometrekareye ulaşmıştır. Dolayısıyla, 2000'den 2020'ye kadar yaş tarım arazilerinde toplamda 164,72 kilometrekarelik bir artış yaşanmıştır.

Yapay yüzeylerin alanı 2000'den 2020'ye 101,02 kilometrekarelik bir artış göstermiştir. Bu artışın 50,88 kilometrekarelik kısmı 2009-2020 arasındaki 11 yıllık döneme, 50,14 kilometrekarelik kısmı ise 2000-2009 arasındaki 9 yıllık döneme denk gelmektedir. Bu gelişme, nüfus artışı ve inşaat faaliyetlerindeki artışla ilişkilendirilebilir.

Google Earth Engine tarafından yapılan hesaplamalara göre su alanları, 2000'den 2009'a doğru 1,36 kilometrekare azalmıştır. 2009 yılından 2020 yılına kadar Porsuk Havzası'nda baraj inşaatlarının artmasıyla su alanlarının 16,25 kilometrekare artmıştır. Toplamda 2000'den 2020'ye kadar su alanlarında 14,90 kilometrekarelik bir artış görülmüştür.

Seyrek ormanların alanı 2000'den 2009'a doğru 490,26 kilometre kare artmıştır. 2009 yılından 2020 yılına kadar bölgedeki mevcut seyrek ormanlar büyüyerek orman haline gelmiştir. Bu süre zarfında seyrek ormanların alanı 438,16 kilometrekare azalmıştır. Dolayısıyla, bu durum orman alanlarının artmasına sebep olmuştur. Toplamda 2000'den 2020'ye kadar seyrek orman miktarı 52,10 kilometrekare artmıştır.

2000 yılından 2009 yılına kadar toprak alanı 1032,32 kilometrekare azalmıştır. Bu azalma oldukça makuldür, çünkü elde edilen sonuçlara göre toprak alanının çoğunlukla orman, yaş tarım alanlarına ve yapay yüzeylere dönüştüğü görülmüştür. 2009 yılından 2020 yılına kadar ise toprak alanı 633,86 kilometrekare azalarak diğer sınıflara dönüşmüştür. Toplamda 2000'den 2020'ye kadar toprak miktarı 1666,18 kilometrekare düşüş göstermektedir.

Kuru tarım arazisi 2000'den 2009'a 255,36 kilometrekare artmış, 2009'dan 2020'ye 117,84 kilometrekare azalmış ve 2000'den 2020'ye toplamda 137,52 kilometrekare artış göstermiştir.

Mera sınıfındaki değişimler şu şekildedir: 2000'den 2009'a 201,32 kilometrekare azalmış, 2009'dan 2020'ye 392,17 kilometrekare artmış ve 2000'den 2020'ye toplamda 191,86 kilometrekare artış göstermiştir.

4.2.3. Sonuçlar

Bu çalışmada, Porsuk Havzası'ndaki Arazi Kullanımı ve Arazi Örtüsü (LULC) araştırması için 2000-2020 yılları arasındaki dönemi kapsayan Landsat uydu görüntülerini Google Earth Engine (GEE) platformunda kullanılmıştır.

Bu çalışmada, Porsuk Havzası'ndaki değişim analizi için sırasıyla 2020, 2009 ve 2000 yıllarında Landsat-8, Landsat-5 ve Landsat-7 görüntüleri kullanılmıştır. Bu amaç doğrultusunda, Sınıflandırma ve Regresyon Ağaçları (CART), Rastgele Orman (RF), Destek Vektör Makinesi (SVM) ve Gradyanla Güçlendirilmiş Ağaçlar (GBT) gibi dört farklı makine öğrenme algoritması kullanılmıştır.

Bu çalışmanın temel amacı, kullanılan dört makine öğrenme modelinin performansını karşılaştırmaktır. Ayrıca, Landsat uydusunun termal bantları ve spektral indekslerin kullanımının sınıflandırmaya etkisini araştırmak amacıyla iki farklı veri seti kullanılmıştır. İlk veri seti sadece Landsat'ın optik bantlarını içerirken, ikinci veri seti ise Landsat'ın optik bantlarına ek olarak termal bantları ve spektral indeksleri de içermektedir.

Porsuk Havzası'nda arazi kullanımı sınıflandırması ve değişim analizi için kullanılan yöntemler arasında, genel doğruluk ve Kappa katsayısına dayalı olarak en iyi sonuçlar Rastgele Orman yöntemine aittir.

İlk veri seti için, en iyi genel doğruluğu Rastgele Orman algoritmasının 2000, 2009 ve 2020 yılları için sırasıyla %85, %89,38 ve %87,5 ve Kappa katsayısı değerleri sırasıyla 0,75, 0,78, 0,82 elde edilmiş, ancak en kötü sonuçlar CART algoritmasının 2000, 2009 ve 2020 yılları için sırasıyla %78,13, %81,63 ve %84,38 ve Kappa katsayısı değerleri sırasıyla 0,83, 0,88, 0,86 elde edilmiştir. Sınıflandırma sonuçlarını iyileştirmek için ilk veri setine Landsat'ın termal bantları ve Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI), Normalleştirilmiş Fark Yapı İndeksi (NDBI), Yeni Yapı İndeksi (NBI) ve Normalleştirilmiş Fark Su İndeksi (NDWI) gibi çeşitli indeksleri eklenmiştir.

İkinci veri setini kullanan Rastgele Orman algoritmasıyla 2000, 2009 ve 2020 yılları için sırasıyla %89,35, %91,88 ve %90,62 genel doğruluk ve Kappa katsayısı değerleri sırasıyla 0,88, 0,91 ve 0,89 elde edilmiştir. Bu durumda, eklenen indeksler ve termal bantların genel doğruluğu artırdığını göstermektedir.

Porsuk havzası'nı sekiz sınıfa ayırdık: ormanlar, seyrek ormanlar, yaş tarım alanları, kuru tarım alanları, yapay yüzeyler, su alanları, toprak ve meralar. Rastgele Orman yöntemini kullanarak gerçekleştirilen arazi kullanımı değişim analizinde, 2000 ile 2020 yılları arasında Porsuk Havzası'nda önemli değişiklikler tespit edilmiştir. Bu değişiklikler arasında yerleşim alanlarının 101,02 kilometrekarelik bir artış gösterdiği ve orman alanlarının 1003,19 kilometrekarelik bir artış gösterdiği belirlenmiştir.

Bu çalışmada sorulan araştırma soruları şu şekilde cevaplanmıştır:

- Porsuk Havzası'nda, Landsat optik bantlarıyla birlikte Landsat termal bantı ve NDVI, NDBI, NBI ve NDWI gibi spektral indeksler, arazi kullanımı analizi için daha etkili olmuştur.
- Porsuk Havzası'ndaki arazi kullanım sınıflandırılması için en uygun yöntem olarak Rastgele Orman yöntemi seçilmiştir. Bu yöntem, diğer yöntemlere göre daha iyi sonuçlar vermiş ve arazi kullanım sınıflandırmasında daha etkili bir yöntem olarak değerlendirilmiştir.
- Rastgele Orman yöntemini kullanılarak yapılan arazi kullanım değişikliği analizi sonucunda, 2000 yılından 2020 yılına kadar Porsuk Havzası'ndaki önemli değişiklikler tespit edilmiştir.
- Termal bant ve indekslerin kullanılması, sadece uydu görüntüleri ile yapılan sınıflandırmaya kıyasla daha iyi bir sınıflandırma ve doğrulama sonucu sağlamıştır.
- Porsuk Havzası'ndaki kentsel alanları diğer sınıflardan ayırt etme zorluğu spektral indekslerin yardımıyla aşılmaktadır.
- Çalışma alanı dört adet Landsat görüntüsünü içermektedir ve geniş bir alanı kapsadığından, uygun görüntülerin seçimi zorlu olmuştur. Ancak, bu koşulları göz önünde bulundurarak, hem tarih hem de bulut oranı açısından en uygun görüntüler seçilmiştir.

Bu çalışmada önerilen hipotezler şu şekilde doğrulanmıştır:

- Termal bant ve indeksler ile birlikte, sadece uydu görüntüleri kullanmaktan daha iyi bir sınıflandırma ve doğrulama sonucu elde edilmiştir.
- En iyi sınıflandırma yöntemi, çalışma alanımızın kriterlerine göre Rastgele Orman yöntemi olarak belirlenmiştir.

5. TARTIŞMA VE ÖNERİLER

Porsuk Havzası'nda arazi kullanım değişikliklerini sınıflandırma ve belirleme üzerine daha önce herhangi bir çalışma yapılmadığı için, bu konuyu araştırmamızın ana nedeni olmuştur. Bu çalışma, 2000 ile 2020 arasındaki 20 yıllık bir süreçte gerçekleştirilmiştir. Porsuk Havzası'nın geniş bir alan değerlendirilmesi gerekliliği ve aynı tarih aralıklarında düşük bulut oranına sahip uydu verilerine zor erişilmesi, bu çalışmada Google Earth Engine (GEE) platformunun (Arpitha et al., 2023; Basheer et al., 2022; Loukika et al., 2021; Ouchra et al., 2023; Rana et al., 2022; Z. Zhao et al., 2024) kullanılmasına sebep olmuştur. Bu platformun bir dizi Landsat uydu verisi toplamak ve istenilen tarihi kullanarak bu verileri filtrelemek kabiliyetiyle, bulut örtüsünün az olduğu uydu görüntüleri ve aynı tarih aralıklarında uydu verileri seçilerek, veri toplama sürecimizdeki sorunları önemli ölçüde azaltmıştır.

Bu çalışmada, Porsuk Havzası'ndaki su alanları, yapay yüzeyler, toprak, yaş tarım arazileri, kuru tarım araziler, meralar, seyrek ormanlar ve ormanların sınıflandırılması için Landsat 5, 7, 8 uydu görüntülerinin optik (Bonansea et al., 2021; Elagouz et al., 2020; Kumar et al., 2020) ve termal bantları kullanılmıştır. Ayrıca NDVI (Z. Zhao et al., 2024), NDWI (Loukika et al., 2021), NDBI (Ouchra et al., 2023) ve NBI gibi spektral indeksler de analizlerde kullanılmıştır. Bu çalışmada dört farklı kontrollü makine öğrenmesi algoritması uygulanmıştır: SVM (Basheer et al., 2022), RF (Ha et al., 2020), CART (Arpitha et al., 2023) ve Gradyanla Güçlendirilmiş Ağaçlar (Ouchra et al., 2023).

Bu çalışma, en iyi sınıflandırma algoritmalarını belirlemek için farklı sınıflandırma algoritmalarının performansını genel doğruluk, kappa katsayısı ve hata matrisi açısından değerlendirmiştir. Ayrıca, Google Earth Engine platformu ve farklı Landsat uydu görüntüleri kullanılarak, bu platformun sınıflandırma kabiliyeti analiz edilmiştir.

Bu çalışmanın yeniliği, Ratgele Orman, SVM ve CART (Loukika et al., 2021; Yang et al., 2021) gibi sıklıkla kullanılan algoritmaların yanı sıra Gradyanla Güçlendirilmiş Ağaçlar gibi daha az yaygın kullanılan bir algoritmanın kullanılmasıdır.

Sonuçlar, Landsat uydularının termal bantlarının (Lee et al., 2015; Mushore et al., 2017; J. Zhao et al., 2019) ve spektral indekslerinin eklenmesiyle elde edilen sınıflandırma haritalarının ve yöntemlerin doğrulama sonuçları açısından daha iyi performans gösterdiğini göstermektedir. Ayrıca, Porsuk Havzası'ndaki arazi kullanımını sınıflandırmak için en uygun ve etkili yöntemin Rastgele Orman (Yang et al., 2021)

yöntemi olduğu belirlenmiştir. Bu yöntem, farklı arazi kullanım sınıflarını başarılı bir şekilde ayırt edebilme konusunda diğer yöntemlere kıyasla daha başarılı olmuştur.

Bu çalışmanın sunduğu sonuçlardan, GEE platformunun bulut mimarisi sayesinde güvenilirliği ve uyarlanabilirliğinin, ENVI, ERDAS (Lossou et al., 2019; Tadese et al., 2020; Thanh Noi & Kappas, 2017) ve diğer ticari yazılımların entegrasyonundan kaçınmamıza olanak sağladığı sonucuna varılmıştır. Ayrıca, Google Earth Engine'in kullanılması analiz zamanından tasarruf sağlamıştır.

Daha önceki çalışmalarda incelendiği gibi, bu çalışmaların hiçbiri tüm veri setleri için sınıflandırma haritaları üretmemiştir. Başka bir deyişle, sadece en iyi senaryolarına göre sınıflandırma haritaları üretmemiştir. Bu çalışmada ise, iki farklı veri setinin uygulanması arasındaki farkı görsel olarak göstermek amacıyla, her iki veri seti için sınıflandırma haritaları üretilmiştir. Bu çalışmada üretilen sınıflandırma haritaları, Şekil 4.6'dan Şekil 4.29'a kadar olan aralıkta sunulmuştur.

Tablo 4-3'ten Tablo 4-14'e kadar görüldüğü gibi farklı yıllarda, her algoritmanın hangi sınıfı daha iyi sınıflandırdığını belirlemek için, her bir algoritmanın 2000, 2009 ve 2020 yıllarına ait hata matrislerini birbiriyle karşılaştırılmıştır. Önceki çalışmalarda bu şekilde bir analiz yapılmamıştır. Bu karşılaştırmanın sonuçları şu şekildedir:

2000 yılı için sınıflandırma yöntemleri arasında, CART yöntemi dışında diğer yöntemler, orman sınıfını doğru bir şekilde sınıflandırmıştır. Yaş tarım ve su alanların sınıfı tüm yöntemlerde doğru bir şekilde sınıflandırılmıştır. Yapay yüzey, mera, toprak ve seyrek orman sınıfları, Rastgele Orman ve Gradyanla Güçlendirilmiş Ağaçlar yöntemlerinde, CART ve SVM yöntemlerine göre daha iyi bir şekilde sınıflandırılmıştır. Kuru tarım alanı sınıfı, sadece Rastgele Orman yöntemiyle daha iyi bir şekilde sınıflandırılmıştır. 2009 yılı için sınıflandırma yöntemleri arasında Cart yöntemi dışında diğer yöntemler, orman ve seyrek orman sınıflarını doğru bir şekilde sınıflandırmıştır. Yaş tarım ve su alanların sınıfı, tüm yöntemlerde doğru bir şekilde sınıflandırılmıştır. Yapay yüzeyler sınıfı, Rastgele Orman ve CART yöntemlerinde, Gradyanla Güçlendirilmiş Ağaçlar ve SVM yöntemlerine göre daha iyi bir şekilde sınıflandırılmıştır. Toprak ve mera sınıfları, Rastgele Orman yönteminde diğer yöntemlere göre daha iyi bir şekilde sınıflandırılmıştır. Kuru tarım alan sınıfı, Gradyanla güçlendirilmiş Ağaçlar ve SVM yöntemleriyle daha iyi bir şekilde sınıflandırılmıştır. 2020 yılı için sınıflandırma yöntemleri arasında, Cart yöntemi dışında diğer yöntemler, yaş tarım alanlarını doğru bir şekilde sınıflandırmıştır. Orman, kuru tarım alanları ve su alanların sınıfı, tüm

yöntemlerde doğru bir şekilde sınıflandırılmıştır. Yapay yüzeyler sınıfı, tüm yöntemlerde neredeyse aynı seviyede iyi bir şekilde sınıflandırılmıştır. Ayrıca 2000 ve 2009 yıllarının yapay yüzeyler sınıfına göre oldukça başarılı sonuçlar elde edilmiştir. Seyrek orman sınıfı, Cart yönteminde hafif bir gerileme göstermiştir; ancak diğer yöntemlerle benzer doğrulukla sınıflandırılmıştır. Toprak ve mera sınıflarında en doğru sınıflandırma, SVM yöntemiyle yapılmıştır.

Bu çalışmanın sınırlılıkları da dikkate alınmalıdır. Düşük çözünürlüklü uydu görüntüleri, çalışma alanının genişliği ve bununla birlikte, uydu görüntülerinin tarih uyumunun zorluğu da önemli bir sınırlılık olabilir. Farklı zamanlarda çekilen görüntülerin atmosferik koşullar, ışık koşulları ve diğer faktörlerden etkilenmesi, analizlerinin doğruluğunu ve güvenilirliğini etkileyebilir. Bu çalışmada yer kontrol noktalarının bulunmaması ve zaman ile maliyet tasarrufu sağlamak amacıyla, yer kontrol noktalarının seçiminde Google Earth uygulamasından (Asare et al., 2021; Edan et al., 2021) yararlanmıştır. Bu çalışmada ücretli verilere göre çözünürlüğü düşük olan Landsat görüntüleri ile yüksek doğrulukta sınıflandırılmış haritalar üretilmiştir. Tüm bu sınırlılıklar, veri toplama ve analiz sürecini etkileyebilir ve elde edilen sonuçların doğruluğunu azaltabilir. Bu nedenle, gelecekte benzer çalışmalar yapılırken, bu sınırlılıkların göz önünde bulundurulması ve analizlerin bu faktörlerin etkilerini minimize etmeye yönelik stratejilerle desteklenmesi önemlidir. Bu stratejiler, arazi kullanımı değişikliklerini daha doğru ve güvenilir bir şekilde belirlemek için gereklidir.

Porsuk Havzası'ndaki arazi kullanımı değişimine odaklanan çalışmalar için öneriler sunmaktadır. Bu öneriler, daha yüksek çözünürlüklü uydu görüntülerinin kullanılması, farklı coğrafi bilgi teknolojilerinin entegre edilmesi ve saha çalışmalarının artırılmasıyla elde edilen doğruluk ve güvenilirlik düzeyi yükselterek, uzaktan algılama tekniklerinin sağladığı verilerin daha etkili bir şekilde kullanılmasını sağlar.

Gelecekteki çalışmalarda planlamak istediğimiz stratejiler şu şekildedir: Diğer makine öğrenme algoritmaları ve derin öğrenme modellerini incelemek, uydu görüntülerini daha iyi sınıflandırmak için farklı algoritmaları kullanmak veya farklı algoritmaların güçlü yönlerini birleştirmek, kentsel alanları daha iyi sınıflandırılması için yüksek çözünürlüklü uydu görüntülerini kullanmak ve Landsat görüntülerini diğer uydu görüntüleriyle birleştirmenin sonuçlar üzerinde etkisini araştırmaktır.

Sonuç olarak, Porsuk Havzası'nda arazi kullanım değişim analizi için coğrafi bilgi teknolojileri ve uydu görüntülerinin kullanımı, havza yönetimi ve arazi kullanımı

planlaması için kritik bir katkı sağlamaktadır. Bu çalışmanın sonuçları, gelecekteki araştırmaların yapılmasına ve Porsuk Havzası'nın daha sürdürülebilir bir şekilde yönetilmesine önemli bir temel oluşturmaktadır. Bu çerçevede, Porsuk Havzası'nın ekolojik dengesinin korunması ve doğal kaynakların sürdürülebilir bir şekilde kullanılması için önemli adımlar atılabilir.



KAYNAKÇA

- Abburu, S., & Golla, S. (2015). Satellite Image Classification Methods and Techniques: A Review. *International Journal of Computer Applications*, 119, 20–25. <https://doi.org/10.5120/21088-3779>
- Abdulaziz M, J. M. H. & R. A.-D. (2009). 25 Application of multitemporal Landsat data to monitor land cover the Eastern Nile Delta region, Egypt. *International Journal of Remote Sensing*, 2977–2996.
- Alavi Panah, S. K., De Dapper, M., Goossens, R., & Massoudi, M. (2001). The Use of TM Thermal Band for Land Cover/Land Use Mapping in Two Different Environmental Conditions of Iran. In *J. Agric. Sci. Technol* (Vol. 3).
- Alberg, A., Park, J., Hager, B., Brock, M., & Diener-West, M. (2004). The Use of “Overall Accuracy” to Evaluate the Validity of Screening or Diagnostic Tests. *Journal of General Internal Medicine*, 19, 460–465. <https://doi.org/10.1111/j.1525-1497.2004.30091.x>
- Arpitha, M., Ahmed, S., & Harishnaika, N. (2023). Land use and land cover classification using machine learning algorithms in google earth engine. *Earth Science Informatics*, 16, 1–17. <https://doi.org/10.1007/s12145-023-01073-w>
- Asare, A., Thodsen, H., Antwi, M., Opuni-Frimpong, E., & Sanful, P. O. (2021). Land Use and Land Cover changes in Lake Bosumtwi Watershed, Ghana (West Africa). *Remote Sensing Applications: Society and Environment*, 23. <https://doi.org/10.1016/j.rsase.2021.100536>
- Ayoub, A. T., Oldeman, L. R., Hakkeling, R. T. A., & Sombroek, W. G. (1991). World map of the status of human-induced soil degradation : a brief explanatory note . *International Soil Reference and Information Centre*.
- Basheer, S., Wang, X. (Xander), Farooque, A., Nawaz, R., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*, 14, 4978. <https://doi.org/10.3390/rs14194978>
- Breiman, L. (1996). *Bagging Predictors* (Vol. 24).
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/J.ISPRSJPRS.2016.01.011>
- Bonansea, M., Bazán, R., Germán, A., Ferral, A., Beltramone, G., Cossavella, A., & Pinotti, L. (2021). Assessing land use and land cover change in Los Molinos reservoir watershed and the effect on the reservoir water quality. *Journal of South American Earth Sciences*, 108. <https://doi.org/10.1016/j.jsames.2021.103243>
- Bouzekri, S., Lasbet, A., & Lachehab, A. (2015). A New Spectral Index for Extraction of Built-Up Area Using Landsat-8 Data. *Journal of the Indian Society of Remote Sensing*, 43. <https://doi.org/10.1007/s12524-015-0460-6>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010950718922>

- Cai, X., McKinney, D. C., & Rosegrant, M. W. (2003). Sustainability analysis for irrigation water management in the Aral Sea region. *Agricultural Systems*, 76(3), 1043–1066.
- Callens, A., Morichon, D., Delpey, M., Liquet, B., & Abadie, S. (2020). Using Random forest and Gradient boosting trees to improve wave forecast at a specific location. *Applied Ocean Research*, 104. <https://doi.org/10.1016/j.apor.2020.102339>
- Çellek, S. (2020). *Effect of the Slope Angle and Its Classification on Landslide*. <https://doi.org/10.21203/rs.3.rs-61660/v1>
- Chandra, S. (1990). Hydrology in ancient India. *National Institute of Hydrology, Roorkee, India*.
- Cheshta Dhingra. (2020, December 28). *A Visual Guide to Gradient Boosted Trees (XGBoost)*. Towards Data Science.
- Da, C., Chagas, S., Antônio, C., Vieira, O., Elpídio, I., & Fernandes, F. (2012). COMPARISON BETWEEN ARTIFICIAL NEURAL NETWORKS AND MAXIMUM LIKELIHOOD CLASSIFICATION IN DIGITAL SOIL MAPPING. In *Rua Jardim Botânico, R. Bras. Ci. Solo* (Vol. 37, Issue 1).
- Edan, M. H., Maarouf, R. M., & Hasson, J. (2021). Predicting the impacts of land use/land cover change on land surface temperature using remote sensing approach in Al Kut, Iraq. *Physics and Chemistry of the Earth*, 123. <https://doi.org/10.1016/j.pce.2021.103012>
- Elagouz, M. H., Abou-Shleel, S. M., Belal, A. A., & El-Mohandes, M. A. O. (2020). Detection of land use/cover change in Egyptian Nile Delta using remote sensing. *Egyptian Journal of Remote Sensing and Space Science*, 23(1), 57–62. <https://doi.org/10.1016/j.ejrs.2018.10.004>
- Ershad, M., & Ali, E. (2020). *Geographic Information System (GIS): Definition, Development, Applications & Components*.
- Eswaran, H., & Samra, J. S. (1997). Challenges in ecosystem management in a management in a watershed context in Asia. *Integrated Watershed Management in the Global Ecosystem*. CPC Press, Boca Raton, 19–32.
- Ffolliott, P. F. (2002). *Land stewardship through watershed management: perspectives for the 21st century*. Springer Science & Business Media.
- Friedl, M. A., McIver, D. K., Hodges, J. C. F., Zhang, X. Y., Muchoney, D., Strahler, A. H., Woodcock, C. E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., & Schaaf, C. (2002). Global land cover mapping from MODIS: algorithms and early results. *Remote Sensing of Environment*, 83(1–2), 287–302. [https://doi.org/10.1016/S0034-4257\(02\)00078-0](https://doi.org/10.1016/S0034-4257(02)00078-0)
- Gessesse, A. A., & Melesse, A. M. (2019). Temporal relationships between time series CHIRPS-rainfall estimation and eMODIS-NDVI satellite images in Amhara Region, Ethiopia. *Extreme Hydrology and Climate Variability: Monitoring, Modelling, Adaptation and Mitigation*, 81–92. <https://doi.org/10.1016/B978-0-12-815998-9.00008-7>

- Ghafouri, M., Siadat, H., & Oweis, T. (2012). *Integrated watershed management in the upper catchments of Karkheh River Basin of Iran*.
- Ghosh, A., Sharma, R., & Joshi, P. K. (2014). Random forest classification of urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion. *Applied Geography*, 48, 31–41. <https://doi.org/10.1016/J.APGEOG.2014.01.003>
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294–300. <https://doi.org/10.1016/J.PATREC.2005.08.011>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. <https://doi.org/10.1016/J.RSE.2017.06.031>
- Gruber, S., & Peckham, S. (2009). Chapter 7 Land-Surface Parameters and Objects in Hydrology. *Developments in Soil Science*, 33(C), 171–194. [https://doi.org/10.1016/S0166-2481\(08\)00007-X](https://doi.org/10.1016/S0166-2481(08)00007-X)
- Guan, H., Li, J., Chapman, M., Deng, F., Mi, W., & Yang, X. (2013). Integration of orthoimagery and lidar data for object-based urban thematic mapping using random forests. *International Journal of Remote Sensing*, 34, 5166–5186. <https://doi.org/10.1080/01431161.2013.788261>
- Guerra, F., Puig, H., & Chaume, R. (1998). The forest-savanna dynamics from multi-date Landsat-TM data in Sierra Parima, Venezuela. *International Journal of Remote Sensing*, 19(11), 2061–2075. <https://doi.org/10.1080/014311698214866>
- Guha, S., Govil, H., Gill, N., & Dey, A. (2021). A long-term seasonal analysis on the relationship between LST and NDBI using Landsat data. *Quaternary International*, 575–576, 249–258. <https://doi.org/10.1016/J.QUAINT.2020.06.041>
- Guth, P., Van Niekerk, A., Grohmann, C., Muller, J.-P., Hawker, L., Florinsky, I., Gesch, D., Reuter, H., Herrera, V., Riazanoff, S., Lopez-Vazquez, C., Carabajal, C., Albinet, C., & Strobl, P. (2021). Digital Elevation Models: Terminology and Definitions. *Remote Sensing*, 13. <https://doi.org/10.3390/rs13183581>
- Ha, T. V., Tuohy, M., Irwin, M., & Tuan, P. V. (2020). Monitoring and mapping rural urbanization and land use changes using Landsat data in the northeast subtropical region of Vietnam. *Egyptian Journal of Remote Sensing and Space Science*, 23(1), 11–19. <https://doi.org/10.1016/j.ejrs.2018.07.001>
- He, C., Shi, P., Xie, D., & Zhao, Y. (2010). Improving the normalized difference built-up index to map urban built-up areas using a semiautomatic segmentation approach. *Remote Sensing Letters*, 1, 213–221. <https://doi.org/10.1080/01431161.2010.481681>
- Hsu, C., Chang, C., & Lin, C.-J. (2003). *A Practical Guide to Support Vector Classification* Chih-Wei Hsu, Chih-Chung Chang, and Chih-Jen Lin.
- Jawak, S., Devliyal, P., & Luis, A. (2015). A Comprehensive Review on Pixel Oriented and Object Oriented Methods for Information Extraction from Remotely Sensed

- Satellite Images with a Special Emphasis on Cryospheric Applications. *Advances in Remote Sensing*, 4, 177–195. <https://doi.org/10.4236/ars.2015.43015>
- Jieli, C., Manchun, L., Liu, Y., Chenglei, S., & Wei, H. (2010). *Extract residential areas automatically by New Built-up Index*. 1–5. <https://doi.org/10.1109/GEOINFORMATICS.2010.5567823>
- Karcher, S. C., VanBriesen, J. M., & Nietch, C. T. (2013). Alternative land-use method for spatially informed watershed management decision making using SWAT. *Journal of Environmental Engineering*, 139(12), 1413–1423.
- Kaya, Z., & Dervisoglu, A. (2023). Determination of Urban Areas Using Google Earth Engine and Spectral Indices; Esenyurt Case Study. *International Journal of Environment and Geoinformatics*, 10, 1–8. <https://doi.org/10.30897/ijegeo.1214001>
- Kumar, S., Shwetank, & Jain, K. (2020). A Multi-Temporal Landsat Data Analysis for Land-use/Land-cover Change in Haridwar Region using Remote Sensing Techniques. *Procedia Computer Science*, 171, 1184–1193. <https://doi.org/10.1016/j.procs.2020.04.127>
- Kupfer, J. A., & Emerson, C. W. (2005). Remote Sensing. In K. Kempf-Leonard (Ed.), *Encyclopedia of Social Measurement* (pp. 377–383). Elsevier. <https://doi.org/https://doi.org/10.1016/B0-12-369398-5/00340-6>
- Lambin, E. F., Turner, B., Geist, H. J., Agbola, S., Angelsen, A., Bruce, J. W., Coomes, O., Dirzo, R., Fischer, G., Folke, C., George, P. S., Homewood, K., Imbernon, J., Leemans, R., Li, X., Moran, E., Mortimore, M., Ramakrishnan, P. S., Richards, J. F., & Xu, J. (2001). The causes of land-use and land-cover change: Moving beyond the myths. *Global Environmental Change-Human and Policy Dimensions 11* (2001). - ISSN 0959-3780, 11.
- Lawrence, R. L., & Wright, A. (2001). Rule-based classification systems using classification and regression tree (CART) analysis. *Photogrammetric Engineering and Remote Sensing*, 67, 1137–1142.
- Lee, M. H., Lee, S. B., Kim, Y., Sa, J., & Eo, Y. D. (2015). Effectiveness of using the TIR band in landsat 8 image classification. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 33(3), 203–209. <https://doi.org/10.7848/ksgpc.2015.33.3.203>
- Le-Xiang, Q., Hai-Shan, C. U. I., & CHANG, J. (2006). Impacts of land use and cover change on land surface temperature in the Zhujiang Delta. *Pedosphere*, 16(6), 681–689.
- Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.
- Lin, H., & Ueta, K. (2012). Lake watershed management: services, monitoring, funding and governance. *Lakes & Reservoirs: Research & Management*, 17(3), 207–223.
- Loisel, H., Jamet, C., & Riedi, J. (2009). Remote Sensing. In *Washington DC American Geophysical Union Geophysical Monograph Series* (Vol. 187). <https://doi.org/10.1029/2008GM000764>

- Lossou, E., Owusu-Prempeh, N., & Agyemang, G. (2019). Monitoring Land Cover changes in the tropical high forests using multi-temporal remote sensing and spatial analysis techniques. *Remote Sensing Applications: Society and Environment*, 16. <https://doi.org/10.1016/j.rsase.2019.100264>
- Loukika, K. N., Keesara, V. R., & Sridhar, V. (2021). Analysis of land use and land cover using machine learning algorithms on google earth engine for Munneru river basin, India. *Sustainability (Switzerland)*, 13(24). <https://doi.org/10.3390/su132413758>
- Lu, D. (2007). A Survey of Image Classification Methods and Techniques for Improving Classification Performance. *International Journal of Remote Sensing*, 28, 823–870. <https://doi.org/10.1080/01431160600746456>
- Lu, D., Mausel, P., Brondízio, E., & Moran, E. (2004). Change Detection Techniques. *International Journal of Remote Sensing*, 25.
- Maitima, J., Olson, J., Mugatha, S., Mugisha, S., & Mutie, I. (2010). *Land use changes, impacts and options for sustaining productivity and livelihoods in the basin of lake Victoria* (Vol. 12).
- Malaperdas, G., & Panagiotidis, V. (2018). The aspects of Aspect: Understanding land exposure and its part in geographic information systems analysis. *Energy & Environment*, 29, 0958305X1876632. <https://doi.org/10.1177/0958305X18766322>
- Mather, P., & Tso, B. (2016). Classification methods for remotely sensed data, second edition. In *Classification Methods for Remotely Sensed Data, Second Edition*. <https://doi.org/10.1201/b12554>
- Mathur, A., & Foody, G. M. (2008). Multiclass and binary SVM classification: Implications for training and classification users. *IEEE Geoscience and Remote Sensing Letters*, 5(2), 241–245. <https://doi.org/10.1109/LGRS.2008.915597>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. In *International Journal of Remote Sensing* (Vol. 39, Issue 9, pp. 2784–2817). Taylor and Francis Ltd. <https://doi.org/10.1080/01431161.2018.1433343>
- McGrath, R. (2010). *Kappa Coefficient*. <https://doi.org/10.1002/9780470479216.corpsy0484>
- Miller, M., Souza, M., Alexander, R., Sanisaca, L., De, A., Teixeira, A., & Appling, A. (2020). Application of the RSPARROW Modeling Tool to Estimate Total Nitrogen Sources to Streams and Evaluate Source Reduction Management Scenarios in the Grande River Basin, Brazil. *Water*, 12. <https://doi.org/10.3390/w12102911>
- Minaei, M., & Kainz, W. (2016). Watershed Land Cover/Land Use Mapping Using Remote Sensing and Data Mining in Gorganrood, Iran. *ISPRS International Journal of Geo-Information*, 5, 57. <https://doi.org/10.3390/ijgi5050057>
- Mishra, P. K., Rai, A., & Rai, S. C. (2020). Land use and land cover change detection using geospatial techniques in the Sikkim Himalaya, India. *Egyptian Journal of Remote Sensing and Space Science*, 23(2), 133–143. <https://doi.org/10.1016/j.ejrs.2019.02.001>

- Montgomery, D. R., Grant, G. E., & Sullivan, K. (1995). Watershed analysis as a framework for implementing ecosystem management 1. *JAWRA Journal of the American Water Resources Association*, 31(3), 369–386.
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247–259. <https://doi.org/10.1016/J.ISPRSJPRS.2010.11.001>
- Mushore, T. D., Mutanga, O., Odindi, J., & Dube, T. (2017). Assessing the potential of integrated Landsat 8 thermal bands, with the traditional reflective bands and derived vegetation indices in classifying urban landscapes. *Geocarto International*, 32(8), 886–899. <https://doi.org/10.1080/10106049.2016.1188168>
- Navalgund, R., V, J., & Roy, P. (2007). Remote sensing applications: An overview. *Current Science*, Vol. 93.
- Neary, D. G. (2000). *Changing perceptions of watershed management from a retrospective viewpoint*. <https://api.semanticscholar.org/CorpusID:130814551>
- Oort, P. (2007). Interpreting the Change Detection Error Matrix. *Remote Sensing of Environment*, 108, 1–8. <https://doi.org/10.1016/j.rse.2006.10.012>
- Oruc, M., Marangoz, A. M., & Buyuksalih, G. (2004). *Comparison of Pixel-Based and Object-Oriented Classification Approaches Using Landsat-7 ETM Spectral Bands*. <https://www.researchgate.net/publication/228457894>
- Otukei, J. R., & Blaschke, T. (2010). Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12(SUPPL. 1). <https://doi.org/10.1016/j.jag.2009.11.002>
- Ouattara, T., Couture, R., Bobrowsky, P., & Moore, A. (2004). *Remote Sensing and Geosciences*.
- Ouchra, H., Belangour, A., & Erraissi, A. (2023). Machine Learning Algorithms for Satellite Image Classification Using Google Earth Engine and Landsat Satellite Data: Morocco Case Study. *IEEE Access*, 1. <https://doi.org/10.1109/ACCESS.2023.3293828>
- Paine, D., & Kiser, J. (2012). *Land-Use Planning* (pp. 353–369). <https://doi.org/10.1002/9781118110997.ch18>
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1), 217–222. <https://doi.org/10.1080/01431160412331269698>
- Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86(4), 554–565. [https://doi.org/10.1016/S0034-4257\(03\)00132-9](https://doi.org/10.1016/S0034-4257(03)00132-9)
- Perera, M. (2017). *Watershed Management* (pp. 71–78).
- Poursanidis, D., Chrysoulakis, N., & Mitraka, Z. (2015). Landsat 8 vs. Landsat 5: A comparison based on urban and peri-urbanland cover mapping. *International*

- Journal of Applied Earth Observation and Geoinformation*, 35(PB), 259–269. <https://doi.org/10.1016/j.jag.2014.09.010>
- Qian, Y., Zhou, W., Yan, J., Li, W., & Han, L. (2015). Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 7(1), 153–168. <https://doi.org/10.3390/rs70100153>
- Rana, D., Kumari, M., & Kumari, R. (2022). Land Use and Land Coverage Analysis with Google Earth Engine and Change Detection in the Sonipat District of the Haryana State in India †. *Engineering Proceedings*, 27(1). <https://doi.org/10.3390/ecsa-9-13366>
- Rango, A. (1975). *Applications of remote sensing to watershed management*. Goddard Space Flight Center.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67(1), 93–104. <https://doi.org/10.1016/J.ISPRSJPRS.2011.11.002>
- Rufino, I., Galvão, C., & Cunha, J. (2019). *Land Use Planning* (p. 619). https://doi.org/10.1007/978-3-319-95885-9_300054
- Salah, M. (2017). A survey of modern classification techniques in remote sensing for improved image classification. *Journal of Geomatics*, 11, 21.
- Schulz, J. J., Cayuela, L., Echeverria, C., Salas, J., & Rey Benayas, J. M. (2010). Monitoring land cover change of the dryland forest landscape of Central Chile (1975-2008). *Applied Geography*, 30(3), 436–447. <https://doi.org/10.1016/j.apgeog.2009.12.003>
- Sellers, P., Dickinson, R., Randall, D., Betts, A., Hall, F., Berry, J., Collatz, G., Denning, S., Mooney, H., Nobre, C., Sato, N., Field, C., & Henderson-Sellers, A. (1997). Modeling the Exchanges of Energy, Water, and Carbon Between Continents and the Atmosphere. *Science*, 275, 502–509.
- Shih, H. chien, Stow, D. A., & Tsai, Y. H. (2019). Guidance on and comparison of machine learning classifiers for Landsat-based land cover and land use mapping. *International Journal of Remote Sensing*, 40(4), 1248–1274. <https://doi.org/10.1080/01431161.2018.1524179>
- Southworth, J. (2004). An assessment of Landsat TM band 6 thermal data for analysing land cover in tropical dry forest regions. *International Journal of Remote Sensing*, 25(4), 689–706. <https://doi.org/10.1080/0143116031000139917>
- Srivastava, P. K., Han, D., Rico-Ramirez, M. A., Bray, M., & Islam, T. (2012). Selection of classification techniques for land use/land cover change investigation. *Advances in Space Research*, 50(9), 1250–1265. <https://doi.org/10.1016/J.ASR.2012.06.032>
- Tadese, M., Kumar, L., Koech, R., & Kogo, B. K. (2020). Mapping of land-use/land-cover changes and its dynamics in Awash River Basin using remote sensing and GIS. *Remote Sensing Applications: Society and Environment*, 19. <https://doi.org/10.1016/j.rsase.2020.100352>

- Teng, J., Xia, S., Liu, Y., Yu, X., Duan, H., Xiao, H., & Zhao, C. (2021). Assessing habitat suitability for wintering geese by using Normalized Difference Water Index (NDWI) in a large floodplain wetland, China. *Ecological Indicators*, 122, 107260. <https://doi.org/10.1016/J.ECOLIND.2020.107260>
- Thanh Noi, P., & Kappas, M. (2017). Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors (Basel, Switzerland)*, 18(1). <https://doi.org/10.3390/s18010018>
- Théau, J. (2017). *Change Detection*. https://doi.org/10.1007/978-3-319-17885-1_129
- Tumer, K., & Ghosh, J. (1996). Analysis of decision boundaries in linearly combined neural classifiers. *Pattern Recognition*, 29(2), 341–348. [https://doi.org/10.1016/0031-3203\(95\)00085-2](https://doi.org/10.1016/0031-3203(95)00085-2)
- Turner, M., & Gardner, R. (2015). *Landscape ecology in theory and practice: Pattern and process, second edition*. <https://doi.org/10.1007/978-1-4939-2794-4>
- Viana, C. M., Oliveira, S., Oliveira, S. C., & Rocha, J. (2019). Land Use/Land Cover Change Detection and Urban Sprawl Analysis. *Spatial Modeling in GIS and R for Earth and Environmental Sciences*, 621–651. <https://doi.org/10.1016/B978-0-12-815226-3.00029-6>
- Vieira, S., Kaymak, U., & Sousa, J. (2010). *Cohen's kappa coefficient as a performance measure for feature selection*. 1–8. <https://doi.org/10.1109/FUZZY.2010.5584447>
- W Yue J Xu, W. T., & Xu, L. (2007). The relationship between land surface temperature and NDVI with remote sensing: application to Shanghai Landsat 7 ETM+ data. *International Journal of Remote Sensing*, 28(15), 3205–3226. <https://doi.org/10.1080/01431160500306906>
- Waqar, M., Mirza, J. F., Mumtaz, R., & Hussain, E. (2012). Development of new indices for extraction of built-up area and bare soil from landsat. *Data*, 1.
- Wijesinghe, D., & Withanage, W. K. N. C. (2021). *Detection of the changes of land use and land cover using remote sensing and GIS in Thalawa DS Division*. 14, 72–86.
- Wulder, M., White, J., Loveland, T., Woodcock, C., Belward, A., Cohen, W., Fosnight, E., Shaw, J., Masek, J., & Roy, D. (2016). The global Landsat archive: Status, consolidation, and direction. *Remote Sensing of Environment*, 185, 271–283. <https://doi.org/10.1016/j.rse.2015.11.032>
- Yang, Y., Yang, D., Wang, X., Zhang, Z., & Nawaz, Z. (2021). Testing accuracy of land cover classification algorithms in the qilian mountains based on gee cloud platform. *Remote Sensing*, 13(24). <https://doi.org/10.3390/rs13245064>
- Zhao, J., Yu, L., Xu, Y., Ren, H., Huang, X., & Gong, P. (2019). Exploring the addition of Landsat 8 thermal band in land-cover mapping. *International Journal of Remote Sensing*, 40(12), 4544–4559. <https://doi.org/10.1080/01431161.2019.1569281>
- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Bibi, T., Rehman, N. U., Ahmad, W., Aslam, R. W., Raza, D., & Hatamleh, W. A. (2024). Comparison of Three Machine Learning Algorithms Using Google Earth Engine for Land Use

- Land Cover Classification. *Rangeland Ecology & Management*, 92, 129–137.
<https://doi.org/https://doi.org/10.1016/j.rama.2023.10.007>
- Zhaohua Chen, J. W. (2010). Land use and land cover change detection using satellite remote sensing techniques in the mountainous Three Gorges Area, China. *International Journal of Remote Sensing*, 31(6), 1519–1542.
<https://doi.org/http://dx.doi.org/10.1080/01431160903475381>
- Zhu, Z., Fu, Y., Woodcock, C., Olofsson, P., Vogelmann, J., Holden, C., Wang, M., Dai, S., & Yu, Y. (2016). Including land cover change in analysis of greenness trends using all available Landsat 5, 7, and 8 images: A case study from Guangzhou, China (2000–2014). *Remote Sensing of Environment*, 185.
<https://doi.org/10.1016/j.rse.2016.03.036>



ÖZGEÇMİŞ

ORCID NO: 0000-0002-1162-5554

Ad Soyad : MILAD DEHGHANIJABBARLOU

Yabancı Dil :

Doğum Yeri ve Yılı :

E-Posta :

Eğitim ve Mesleki Geçmişi:

- Yıl, Üniversite, Enstitü/Fakülte, Bölüm, Anabilim Dalı
- Yıl, Görev, Kurum, Birim

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- Yıl, Yayının/Faaliyetin Türü, Adı ve Bilgileri, Yeri
- Yazarın Soyadı, Adının ilk harfi. (Yayın yılı). Makale adı. Dergi Adı, Cilt (sayı), Sayfa numaraları.

Ödülleri:

- Yıl, Derece, Ödül Adı, Yeri

Mesleki Birlik/Dernek/Kuruluş Üyelikleri:

- Yıl, Birlik/Dernek/Kuruluş Adı, Yeri.