



**UZAKTAN ALGILAMA VE MAKİNE
ÖĞRENMESİ ETKİLEŞİMİ İLE BOR MADEN
SAHALARININ ARAŞTIRILMASI**

Doktora Tezi

Ender KELLEÇİ

Haziran 2024

**UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ ETKİLEŞİMİ İLE BOR
MADEN SAHALARININ ARAŞTIRILMASI**

Ender KELLEÇİ

Doktora Tezi

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Hakan UYGUÇGİL

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Haziran 2024

JÜRİ VE ENSTİTÜ ONAYI

Ender KELLEÇİ'nin UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ ETKİLEŞİMİ İLE BOR MADEN SAHALARININ ARAŞTIRILMASI başlıklı çalışması 24/06/2024 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	: Dr. Öğr. Üyesi Hakan UYGUÇGİL
Üye	: Prof. Dr. Adnan KONUK
Üye	: Prof. Dr. Alper ÇABUK
Üye	: Prof. Dr. Osman PARLAKTUNA
Üye	: Prof. Dr. Tansu FİLİK

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

24/06/2024

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Doktora đrencisi Ender KELLECI, UZAKTAN ALGILAMA VE MAKİNE đRENMESİ ETKİLEřİMİ İLE BOR MADEN SAHALARININ ARAřTIRILMASI bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımda incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Dr. đr. yesi Hakan UYGUGİL

ÖZET

UZAKTAN ALGILAMA VE MAKİNE ÖĞRENMESİ ETKİLEŞİMİ İLE BOR MADEN SAHALARININ ARAŞTIRILMASI

Ender KELLEÇİ

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı
Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Haziran 2024

Danışman: Dr. Öğr. Üyesi Hakan UYGUÇGİL

Nesneler, fiziksel ve kimyasal bileşimlerine göre elektromanyetik radyasyona farklı tepkiler vermektedir. Uyduların radyometrik sensörleri, yeryüzünden elde edilen elektromanyetik yansıma değerlerini çeşitli dalga boylarında kaydeder. Uzaktan algılama farklı yansıma değerleri ile nesnelerin ayırt edilmesi, tanımlanması ve analizinde kullanılmaktadır. Çalışmada, uzaktan algılama ve makine öğrenmesi etkileşimi ile bor madeni arama yöntemlerinin geliştirilmesi amaçlanmıştır.

Stratejik öneme sahip bir mineral olan bor, bu çalışmanın odak noktasıdır. Google Earth Engine kullanılarak, farklı zamanlarda elde edilen uydu görüntüleri bulut ortamında işlenip analiz edilmiştir. Bu yaklaşım ile büyük veri setlerinin hızlı bir şekilde işlenmesi ve analiz edilmesi sağlanarak bor minerali için zaman, uydu adı, makine öğrenmesi yöntemi gibi parametrelere göre sınıflandırma yapan bir uygulama geliştirilmiştir.

Çalışma, uzaktan algılama ve makine öğrenmesi yöntemlerinin yeryüzündeki bor oluşumlarının belirlenmesinde etkili bir şekilde kullanılabildiğini göstermektedir. Bor varlığına işaret eden desenler makine öğrenmesi algoritmaları ile belirlenerek doğru sonuçlara ulaşılmasını sağlamıştır.

Genel olarak, uzaktan algılamanın makine öğrenmesi ile etkileşimi maden aramalarının verimliliğini ve doğruluğunu önemli ölçüde artırmaktadır. Bu araştırma, modern teknolojik araçların maden arama süreçlerinin iyileştirme potansiyelini vurgulamakta ve daha iyi kaynak yönetimi ve kullanım stratejilerine katkıda bulunmaktadır.

Anahtar Sözcükler: Uzaktan Algılama, Google Earth Engine, Makine Öğrenmesi, Bor

ABSTRACT

EXPLORATION OF BORON MINE SITES WITH REMOTE SENSING AND MACHINE LEARNING INTERACTION

Ender KELLEÇİ

Department of Department of Remote Sensing and Geographic Information Systems

Eskişehir Technical University, Institute of Graduate Programs, June 2024

Supervisor: Asst. Prof. Dr. Hakan UYGUÇGİL

Objects respond differently to electromagnetic radiation according to their physical and chemical compositions. Radiometric sensors of satellites record electromagnetic reflection values obtained from the earth's surface at various wavelengths. Remote sensing is used to distinguish, identify and analyze objects with different reflection values. The study aims to develop boron mineral exploration methods with the interaction of remote sensing and machine learning.

Boron, a mineral of strategic importance, is the focus of this study. Using Google Earth Engine, satellite images obtained at different dates were processed and analyzed in the cloud environment. With this approach, large data sets can be processed and analyzed quickly, and an application that classifies boron minerals according to parameters such as time, satellite name and machine learning method has been developed.

The study shows that remote sensing and machine learning methods can be used effectively in determining boron formations on earth. Patterns indicating the presence of boron were determined with machine learning algorithms, ensuring accurate results.

Overall, the interaction of remote sensing with machine learning offers significant improvements in the efficiency and accuracy of mineral exploration. This research underscores the potential of modern technological tools in enhancing mineral exploration processes, ultimately contributing to better resource management and utilization strategies.

Keywords: Remote Sensing, Google Earth Engine, Machine Learning, Boron

TEŞEKKÜR

Bu tezin sahibi olarak her ne kadar adım geçmiş olsa da, bu çalışmanın oluşmasında bana inanan, güvenen, sabreden, emek veren, yönlendiren ve destek verenlere ithaf edilmiştir.

Tanıştığım günden bugüne kadar karşılaştığım her zorlukta yanımda olan, emeğini desteğini hiç esirgemeyen, zorlandığım ve motivasyonumun düştüğü zamanlarda beni yüreklendiren, kendime güvenmemi ve inanmamı sağlayan tez danışmanım, sayın hocam Hakan Uyguçgil'e, bu tez çalışmasının oluşmasında, başta emeği ve sabrı olmak üzere bana olan güven ve desteğinden dolayı teşekkür ediyorum.

Doktora çalışmam süresince doktora devam etmem için sürekli motive eden, sıkıştığım zamanlarda değerli çözüm önerileriyle yardımcı olan Sayın hocam Prof. Dr. Alper Çabuk'a verdiği emek ve destekten dolayı teşekkür ederim.

Doktora çalışmam sırasında değerli yorum ve destekleriyle Sayın Prof. Dr. Tansu Filik'e teşekkürlerimi sunuyorum

Görüşleri ile tezimin şekillenmesini sağlayan değerli jüri üyelerim Prof. Dr. Osman Parlaktuna ve Prof. Dr. Adnan Konuk'a teşekkür ederim.

Tezimin yazılmasında desteklerini hiçbir zaman esirgemeyen sevgili kardeşim Ezgi Kelleci'ye, yol göstericiliği ve manevi desteğinden dolayı her zaman bana rehber olan Nihat Çeliktürker'e, yıllardır sabırla usanmadan tez çalışmamada dahil olmak üzere her türlü zorluğu yenmemde en büyük desteği gösteren, hayat öğretmenlerim Babam İsmet Kelleci ve annem Şükran Kelleci'ye teşekkür ederim.

Ender KELLEÇİ

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.

Ender KELLEÇİ

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.....	XVI
1. GİRİŞ	1
1.1. Çalışmanın Amacı.....	4
1.2. Çalışmanın Özgün Değeri.....	5
1.3. Yaygın Etki / Katma Değer.....	6
1.4. Çalışmanın Kısıtlılıkları.....	6
1.5. Literatür Özeti.....	6
2. KURAMSAL TEMELLER	13
2.1. Uzaktan Algılama	13
2.1.1. Elektromanyetik ışıma	14
2.1.2. Atmosferik etki.....	17
2.1.3. Atmosferik pencereler ve nesnelerin imzası	18
2.1.4. Uzaktan algılamada çözünürlük.....	19
2.1.4.1 Konumsal çözünürlük.....	20
2.1.4.2 Spektral çözünürlük.....	21
2.1.4.3. Radyometrik çözünürlük.....	22
2.1.4.4. Zamansal çözünürlük	22

2.1.5. Uzaktan algılamada sınıflandırma	22
2.1.5.1 Uzaktan algılamada sınıflandırmayı etkileyen faktörler	24
2.1.6. Uzaktan algılamada sahte renk bileşimleri (FCC)	26
2.1.7. Uzaktan algılamada bant oranlama.....	28
2.1.8. Uzaktan algılamada spektral aç haritalama (SAM).....	29
2.1.9. Uzaktan algılamada temel bileşen analizi (PCA).....	29
2.2. Makine Öğrenmesi	30
2.2.1. Makine öğrenmesi ve uzaktan algılama.....	31
2.2.2. Destek vektör makineleri	31
2.2.3. Karar ağaçları.....	33
2.2.4. Sınıflandırma ve regresyon ağaçları	36
2.2.5. Rastgele orman	37
2.2.6. K-ortalamlar	38
2.2.7. Öğrenmeli vektör kuantalama (LVQ)	39
3. MATERYAL VE YÖNTEM	41
3.1. Çalışma Alanı.....	41
3.2. Google Earth Engine (GEE).....	44
3.3. Kullanılan Uydu ve Uydu Görüntüleri.....	47
3.3.1. Landsat programı ve uyduları	47
3.3.2. Sentinel uyduları ve Copernicus programı	48
3.4. USGS Spektral Kütüphanesi.....	49
3.4.1. USGS kütüphanesi bor minerali ve spektral özellikleri.....	51
3.5. Kullanılan Uzaktan Algılama Yöntemleri.....	53
3.5.1. Sahte renk bileşimleri.....	54
3.5.2. Bant oranlama.....	59
3.5.2.1. Landsat8 görüntüleri ile bant oranlama çalışmaları	59
3.5.2.2 Sentinel-2 görüntüleri ile bant oranlama çalışmaları	62
3.5.3. Spektral aç haritalama.....	64
3.5.3.1. Landsat8 görüntüleri ile SAM.....	65
3.5.3.2. Sentinel-2 görüntüleri ile SAM.....	68
3.5.4. Temel bileşen analizi.....	70
3.5.4.1. Landsat8 görüntüleri ile PCA.....	71

3.5.4.2. Sentinel-2 görüntüleri ile PCA.....	74
3.6. Kullanılan Makine Öğrenmesi Yöntemleri.....	78
3.6.1. Denetimsiz k-means.....	78
3.6.1.1. Landsat8 görüntüleri ile denetimsiz k-means.....	78
3.6.1.2. Sentinel-2 görüntüleri ile denetimsiz k-means.....	80
3.6.2. Denetimsiz LVQ.....	81
3.6.2.1. Landsat8 görüntüleri ile denetimsiz LVQ.....	81
3.6.2.2. Sentinel-2 görüntüleri ile denetimsiz LVQ.....	82
3.6.3. Destek vektör makineleri.....	83
3.6.3.1. Landsat8 görüntüleri ile SVM.....	83
3.6.3.2. Sentinel-2 görüntüleri ile SVM.....	85
3.6.4. Sınıflandırma ve regresyon ağaçları.....	85
3.6.4.1 Landsat8 görüntüleri ile CART.....	85
3.6.4.2 Sentinel 2 görüntüleri ile CART.....	86
3.6.5. Rasgele orman.....	86
3.6.5.1 Landsat 8 görüntüleri ile RF.....	86
3.6.5.2 Sentinel 2 görüntüleri ile RF.....	87
3.7. Bor Kaşifi.....	87
4. SONUÇLAR VE ÖNERİLER.....	92
KAYNAKÇA.....	95
EKLER	
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 1.1. Referans çalışmaları	8
Tablo 1.2. (Devam) Referans çalışmaları	9
Tablo 1.3. (Devam) Referans çalışmaları	10
Tablo 1.4. (Devam) Referans çalışmaları	11
Tablo 3.1. Landsat 8 bantları (http-2).....	48
Tablo 3.2. Sentinel 2 bantları (http-3)	49
Tablo 3.3. Öz değerler.....	71
Tablo 3.4. PCA varyans oranı	71
Tablo 3.5. Öz değerler.....	74
Tablo 3.6. Varyans oranı.....	75
Tablo 4.1. Makine öğrenmesi karşılaştırma.....	93

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Nesnelerin dalga boylarına göre karakteristikleri (Yılmaz, 2015)	3
Şekil 1.2. Bazı minerallerin spektral imzası (Sabins, 1987)	4
Şekil 2.1. Pasif uzaktan algılama işleyişi	14
Şekil 2.2. Elektromanyetik dalga parametreleri (Tempfli, et al., 2009)	15
Şekil 2.3. Elektromanyetik dalganın enerji ve dalga boyu ilişkisi (http-1)	16
Şekil 2.4. Elektromanyetik tayf (Rayar et al., 2023)	16
Şekil 2.5. Elektromanyetik enerjinin üç temel etkileşimi (Çölkesen, 2015)	18
Şekil 2.6. Toprak, bitki ve su için spektral yansıtım grafiği (Lillesand ve ark, 2004)	19
Şekil 2.7. Uydu anlık görüş alanı	20
Şekil 2.8. Konumsal çözünürlük	21
Şekil 2.9. Spektral açı haritalama (Muhammad & Saepuloh, 2016)	29
Şekil 2.10. Optimum hiperdüzlem (Çölkesen,2015)	32
Şekil 2.11. Destek vektör makineleri ile iki sınıflı veri setinin sınıflandırılması (Çölkesen,2015)	33
Şekil 2.12. Üç sınıfa sahip dört bantlı veri seti için oluşturulan karar ağacı yapısı (Çölkesen, 2015)	34
Şekil 2.13. Rastgele orman algoritmasının temel çalışma prensibi (Çölkesen,2015) ..	38
Şekil 3.1. Çalışma alanı	41
Şekil 3.2. Kırka bor yatakları	42
Şekil 3.3. Hidrotermal yapı	42
Şekil 3.4. Kırka kayaç yapısı-1	43
Şekil 3.5. Kırka kayaç yapısı-2	44
Şekil 3.6. Lantsat8 OLI ve Sentinel-2 MSI uydu bantlarının dalga boyu cinsinden karşılaştırılması (Sigurdsson ve ark, 2022)	49
Şekil 3.7. Beckman spektrometresine (splib07a) göre laboratuvar ortamında elde edilen spektral	52
Şekil 3.8. Sentinel-2 MSI (s7SNTL2) yanıt fonksiyonlarına göre yeniden örneklenmiş spektral değerler	53
Şekil 3.9. Landsat 8 bantlarının yüzey yansıma değerlerine göre bant histogramları	55

Şekil 3.10. Sentinel 2 bantlarının yüzey yansıma değerlerine göre bant histogramları.....	55
Şekil 3.11. Landsat 8 sahte renk bileşimi (Bant 6-5-4)	56
Şekil 3.12. Landsat 8 sahte renk birleşimi (Bant 7-6-5).....	57
Şekil 3.13. Sentinel 2 sahte renk bileşimi (Bant 12-8A-4).....	58
Şekil 3.14. Sentinel 2 sahte renk birleşimi (Bant 11-12-8A)	58
Şekil 3.15. Sentinel 2 sahte renk birleşimi (Bant 11-8-2)	59
Şekil 3.16. Bant5/Bant7 Bant oranı gösterimi	60
Şekil 3.17. Bant4/Bant7 Bant oranı gösterimi	61
Şekil 3.18. Bant5/Bant4 Bant oranı gösterimi	61
Şekil 3.19. Bant oranlarının sahte renk birleşimi gösterimi	62
Şekil 3.20. Bant11/Bant5 Bant oranı gösterimi	63
Şekil 3.21. Bant7/Bant5 Bant oranı gösterimi	63
Şekil 3.22. Bant12/Bant5 Bant oranı gösterimi	64
Şekil 3.23. Bant oranlarının sahte renk birleşimi gösterimi	64
Şekil 3.24. Landsat 8 bantlarına göre bor minerallerinin yansıma değerleri gösterimi	65
Şekil 3.25. Landsat 8 bantlarının dalgaboylarına göre bor minerallerinin yansıma değerleri gösterimi	65
Şekil 3.26. Landsat 8 tıncal spektral açısı haritalaması.....	66
Şekil 3.27. Landsat 8 kolemanit spektral açısı haritalaması.....	66
Şekil 3.28. Landsat 8 uleksit gd138 spektral açısı haritalaması	67
Şekil 3.29. Landsat 8 uleksit hd441 spektral açısı haritalaması	67
Şekil 3.30. Sentinel 2 bantlarına göre bor minerallerinin yansıma değerleri gösterimi	68
Şekil 3.31. Sentinel 2 bantlarının dalgaboylarına göre bor minerallerinin yansıma değerleri gösterimi	68
Şekil 3.32. Sentinel 2 tıncal spektral açısı haritalaması	69
Şekil 3.33. Sentinel 2 kolemanit spektral açısı haritalaması	69
Şekil 3.34. Sentinel 2 uleksit gd138 spektral açısı haritalaması.....	70
Şekil 3.35. Sentinel 2 uleksit hd441 spektral açısı haritalaması.....	70
Şekil 3.36. Landsat 8 temel bileşen analizi PC1.....	72
Şekil 3.37. Landsat 8 temel bileşen analizi PC2.....	72

Şekil 3.38. Landsat 8 temel bileşen analizi PC3	72
Şekil 3.39. Landsat 8 temel bileşen analizi PC4	73
Şekil 3.40. Landsat 8 temel bileşen analizi PC5	73
Şekil 3.41. Landsat 8 temel bileşen analizi PC6	73
Şekil 3.42. Landsat 8 temel bileşen analizi R:PC1,G:PC2,B:PC3	74
Şekil 3.43. Sentinel 2 temel bileşen analizi PC1	75
Şekil 3.44. Sentinel 2 temel bileşen analizi PC2	76
Şekil 3.45. Sentinel 2 temel bileşen analizi PC3	76
Şekil 3.46. Sentinel 2 temel bileşen analizi PC4	76
Şekil 3.47. Sentinel 2 temel bileşen analizi PC5	77
Şekil 3.48. Sentinel 2 temel bileşen analizi PC6	77
Şekil 3.49. Sentinel 2 temel bileşen analizi R:PC1,G:PC2,B:PC3	77
Şekil 3.50. Landsat 8 K-ortalamalar (5 sınıf)	79
Şekil 3.51. Landsat 8 K-ortalamalar (10 sınıf)	79
Şekil 3.52. Landsat 8 K-ortalamalar (15 sınıf)	79
Şekil 3.53. Sentinel 2 K-ortalamalar (5 sınıf)	80
Şekil 3.54. Sentinel 2 K-ortalamalar (10 sınıf)	80
Şekil 3.55. Sentinel 2 K-ortalamalar (15 sınıf)	80
Şekil 3.56. Landsat 8 LVQ (5 sınıf)	81
Şekil 3.57. Landsat 8 LVQ (10 sınıf)	81
Şekil 3.58. Landsat 8 LVQ (15 sınıf)	82
Şekil 3.59. Sentinel 2 LVQ (5 sınıf)	82
Şekil 3.60. Sentinel 2 LVQ (10 sınıf)	82
Şekil 3.61. Sentinel 2 LVQ (15 sınıf)	83
Şekil 3.62. Eğitim ve validasyon seti noktaları	84
Şekil 3.63. Eğitim ve validasyon seti için tutarlılık kontrolü	84
Şekil 3.64. Landsat 8 kullanarak bor minerali bulunan bölgelerin SVM ile gösterilmesi	84
Şekil 3.65. Sentinel 2 kullanarak bor minerali bulunan bölgelerin SVM ile gösterilmesi	85
Şekil 3.66. Landsat 8 kullanarak bor minerali bulunan bölgelerin CART ile gösterilmesi	85

Şekil 3.67. Sentinel 2 kullanarak bor minerali bulunan bölgelerin CART ile gösterilmesi	86
Şekil 3.68. Landsat 8 kullanarak bor minerali bulunan bölgelerin RF ile gösterilmesi	87
Şekil 3.69. Sentinel 2 kullanarak bor minerali bulunan bölgelerin RF ile gösterilmesi	87
Şekil 3.70. Bor kaşifi akışı	88
Şekil 3.71. Bor kaşifi arayüz	89
Şekil 3.72. Uydu seçimi	89
Şekil 3.73. Tarih seçimi	90
Şekil 3.74. Görüntü seçimi	90
Şekil 3.75. Görüntü görselleştirme	91
Şekil 3.76. Algoritma seçimi	91

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Network)
BR	: Bant Oranlama (Band Ratioing)
CART	: Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees)
CBS	: Coğrafi Bilgi Sistemleri
DT	: Karar Ağaçları (Decision Trees)
DEM	: Dijital Yükseklik Modeli (Digital Elevation Model)
DTM	: Sayısal Arazi Modeli (Digital Terrain Model)
EMR	: Elektromanyetik Radyasyon
EMS	: Elektromanyetik Spektrum
ERTS	: Dünya Kaynakları Teknolojisi Uydusu (Earth Resources Technology Satellite)
ESA	: Avrupa Uzay Ajansı
ETM+	: Enhanced Thematic Mapper Plus
FCC	: Sahte Renk Bileşimleri (False Color Combinations)
GEE	: Google Earth Engine
GIS	: Coğrafi Bilgi Sistemleri
LVQ	: Kuantalama (Learning Vector Quantization)
MIR	: Orta Kızılötesi (Middle InfraRed)
ML	: Makine Öğrenmesi (Machine Learning)
MODIS	: (Moderate Resolution Imaging Spectroradiometer)
MSI	: Multispektral Enstrüman
MSS	: Multispectral Scanner System
NASA	: Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration)
NDVI	: Normalleştirilmiş Fark Bitki Örtüsü İndeksi (Normalized Difference Vegetation Index)
NIR	: Yakın Kızılötesi (Near InfraRed)
NOAA	: (National Oceanic and Atmospheric Administration)
PCA	: Temel Bileşenler Analizi (Principal Component Analysis)
RF	: Rastgele Orman (Random Forest)

RTF	: Radyal Tabanlı Fonksiyon
SAM	: Spektral Açık Haritalama (Spectral Angle Mapper)
SVM	: Destek Vektör Makineleri (Support Vector Machine)
SYM	: Sayısal Yükseklik Modeli
SWIR	: Kısa Dalga Kızılötesi (Short Wave InfraRed)
OLI	: Operational Land Imager
TIR	: Termal Kızılötesi (Thermal Infrared)
TM	: Thematic Mapper
TOA	: Atmosfer Zirvesi (Top-of-Atmosphere)
USGS	: Amerika Birleşik Devletleri Jeolojik Araştırmalar Kurumu (United States Geological Survey)
VNIR	: Görünür Yakın Kızılötesi (Visible Near-Infrared)

1. GİRİŞ

Konumsal veri analizi, coğrafi bilgi sistemleri (CBS) ile uzaktan algılama teknolojilerinin yakınlaşmasıyla birlikte bir paradigma değişikliğine uğramıştır. CBS, coğrafi referanslı verilerin toplanması, saklanması, analiz edilmesi ve görüntülenmesi için kapsamlı bir çerçeve işlevi görerek konumsal veri yönetiminin temel unsuru haline gelmiştir. Geleneksel bir veritabanı sisteminin işlevlerini gelişmiş coğrafi araçlarla birleştirerek kullanıcıların yalnızca öznitelik verilerini yönetmesini değil aynı zamanda konumsal ilişkilerini görselleştirmesini ve analiz etmesini sağlar (Goodchild, 2017). Böylece, her alanlarda araştırmacılar ve profesyoneller daha doğru ve daha bilinçli karar verebilmek için konum tabanlı bilginin gücünden yararlanmaya yönelmiştir.

Veri-yaşam döngüsü CBS süreçlerinin temel ilkesini oluşturur. Bu döngü, veri toplama, oluşturma, yorumlama ve yeni içgörüler üretmeye kadar tüm süreci kapsar. Özellikle CBS bu süreçleri coğrafi bağlamda yürütme konusunda çok güçlüdür. Konumsal verileri toplama, ilişkilendirme, sınıflandırma ve analiz detaylı ve karmaşık işlemler sürecini beraberinde gerektirir ve veri içindeki konumsal ilişkileri ortaya çıkarır. Veri toplama ve işleme genellikle veri-yaşam döngüsündeki en önemli maliyet kalemlerini oluşturur. Veri güvenilirliği, kaynak tutarlılığı, erişilebilirlik, üretim kolaylığı ve konumsal denetimin uygulanabilirliği gibi faktörlerin tümü, veri toplama için gereken zamanı ve finansal kaynakları önemli ölçüde etkiler (Longley vd., 2015).


Uzaktan algılama teknolojileri, CBS'deki geleneksel veri toplama yöntemleriyle ilişkili maliyet ve zaman kısıtlamalarını hafifletmek için önemli bir çözüm olarak ortaya çıkmıştır. Başlangıçta öncelikle hava ve uydu görüntülerinden raster veri kümelerinin elde edilmesi olarak tasarlanan uzaktan algılama, konumsal veri toplama ve üretimi için çok yönlü bir araç setine dönüşmüştür. Geniş tanımıyla uzaktan algılama, özel sensörler kullanarak yeryüzü hakkındaki verileri uzaktan toplamak ve analiz etmek için kullanılan teknikleri ve teknolojileri kapsar. Sensörlerin ve veri toplama yöntemlerinin yaygınlaşması, doğal ve insan yapımı yeryüzü oluşumları hakkında daha kapsamlı bilgi edinilmesinin yolunu açmıştır (Jensen, 2005).

Uzaktan algılamanın temeli, yeryüzündeki nesneler tarafından yansıtılan veya emilen elektromanyetik radyasyonun analizine dayanmaktadır. Bu temel prensip, her nesnenin farklı elektromanyetik dalga boylarında benzersiz spektral özellikler sergilediğini kabul eder. Spektral imza, nesnelerin ayırt edilmesine ve sınıflandırılmasına

olarak tanır. Radyometrik sensörlerle donatılmış uydular, çeşitli dalga boyları boyunca yeryüzünden yayılan elektromanyetik yansıma değerlerini yakalar. Elektromanyetik yansıma ve nesneler arasındaki etkileşim, nesnelerin ayrımını, analizini ve tanımlanmasını kolaylaştırmaktadır. Uzaktan algılama jeoloji, madencilik ve tarım gibi disiplinlerde önemini kanıtlanmıştır. Farklı dalga boylarında gözlemlenen yansıma değerlerinin gelişmiş analiz teknikleri ile yorumlanabilmesi, nesnelerin fiziksel ve kimyasal özellikleri hakkında bilinçli tahminlere olanak sağlamaktadır (Thenkabail, 2015). Nesnelerin sergilediği farklı spektral tepkiler, onların sınıflandırılmasını ve ayırt edilmesini kolaylaştırmaktadır. Analiz yöntemlerindeki gelişmeler, birden fazla dalga boyunda çalışabilen, malzemelerin uygun maliyetli sınıflandırılmasını ve aralarındaki ilişkilerin incelenmesini kolaylaştıran multispektral sensörlerin geliştirilmesine yol açmıştır.

Uzaktan algılamanın CBS ile simbiyotik ilişkisi, ekonomik verimliliği, hızı, tutarlılığı ve güvenilirliği nedeniyle uzaktan algılamayı konumsal veri toplamada ön plana çıkarmıştır. Spektral yansıma değişikliklerine dayalı olarak uzaktan algılanan verileri sınıflandırma ve tanımlama yeteneği, bu analizlerin CBS çerçevesinde temel katmanlar olarak kullanılmasına olanak tanır. CBS ve uzaktan algılamanın sinerjik birleşimi, konumsal veri toplama, işleme ve analiz için kullanılan yöntemlerde devrim niteliğindedir. Bu yakınsama yalnızca konumsal veri yönetiminin verimliliğini ve doğruluğunu arttırmakla kalmayıp, aynı zamanda farklı disiplinlerdeki bilimsel araştırma ve pratik uygulamalara yönelik gelişmelere yön vermektedir.


Geçmişte spektral karakteristiklerin birbirinden kolayca ayırt edilebildiği, bitki, toprak ve kayaç türlerinin tespiti, sınıflandırılması ve ayrıştırılmasında kullanılan uzaktan algılama yöntemleri başarılı olmuştur (Şekil 1.1). Böylece önceleri multispektral (4-5 bant) algılayıcıların kullanımı sonraları daha detaylı analizler için amaca bağlı olarak hiperspektral (100'den fazla bant) algılayıcıların kullanımının önünü açmıştır.



Şekil 1.1. Nesnelerin dalga boylarına göre karakteristikleri (Yılmaz, 2015)

Madencilikte spektral yansıma değerleri kullanılarak yapılan çalışmalar sonucu maden arama (Şekil 1.2), terk edilmiş ve işletmesi devam eden maden sahalarının tespiti, maden çalışmalarının çevre etkileri, madencilik sonrası doğa onarım çalışmaları vb. faaliyetler izlenebilmektedir. Landsat ve Sentinel madencilik faaliyetleri için ücretsiz veri sağlayan uydular olarak sayılabilir. Elde edilen verilerin CBS platformuna aktararak işlenmesi ve modellenmesi, madencilik faaliyetlerinin teknoloji odaklı gerçekleştirilmesi, izlenmesi ve yönetilmesini sağlamaktadır.

Ancak bu süreçte uzaktan algılama yöntemleriyle elde edilen verilerin işlenmesi ve sınıflandırılması; madencilik faaliyetleri için verilerin CBS platformuna aktarılması, işlenmesi, analiz ve modellenmesi alan uzmanlarına gereksinim oluşturmuştur. Bu durum, günümüzde makine öğrenmesi (ML) ve yapay zekâ (AI) yöntemlerinin uzaktan algılama ve CBS ile entegrasyonunu gündeme taşımaktadır. Makine öğrenmesi ve yapay zekâ, veri sınıflandırma ve analiz görevlerini otomatikleştirerek maden arama sürecinin maliyetini azaltan, hızlandıran ve kolaylaştıran güçlü bir araç sunmaktadır.



Şekil 1.2. Bazı minerallerin spektral imzası (Sabins, 1987)

Uzaktan algılama, CBS, makine öğrenmesi ve yapay zekânın entegrasyonu, süreci hızlandırmayı ve kolaylaştırmayı amaçlamaktadır. Hassasiyeti artıran hiperspektral sensörler ile elde edilen devasa veri kümelerinin işlenmesi ve saklanması için güçlü donanım ve yazılım altyapıları gerekmektedir. Çözüm olarak ortaya çıkan bulut tabanlı Google Earth Engine benzeri platformlar uzaktan algılama verilerine ulaşımı ve işlenmesini kolaylaştırır. Google Earth Engine petabyte (1024 terabyte) seviyesinde çeşitli spektral çözünürlükte binden fazla uydu görüntüsünü kompleks algoritmalar çalıştırarak online olarak sınıflanmasına ve analizinin yapılmasına olanak sağlar. Bu platformlar, maliyet açısından uygun ve erişilebilir kaynaklar sunar.

1.1. Çalışmanın Amacı

Günümüzde uzaktan algılama ve coğrafi bilgi teknolojileri birçok alanda başarı ile kullanılmaktadır. Uzaktan algılama ve coğrafi bilgi sistemlerinin doğası gereği kullanıldığı alan konusunda bilgi sahibi olmayı zorunlu kılar. Örneğin uzaktan algılama analizlerinin maden aramalarında kullanılabilmesi için aranan mineralin jeolojik oluşumu, yan kayaçları ve yapısal özelliklerinin bilinmesi önemlidir. Uzaktan algılama

yöntemleriyle elde edilen verilerin işlenmesi ve sınıflandırılması; madencilik faaliyetleri için verilerin CBS platformuna aktarılması, analizi ve modellenmesi uzmanlık gerektirir. Madencilik konusunda bilgi birikiminin yanı sıra uzaktan algılama ve coğrafi bilgi teknolojileri konusundaki uzmanlık doğru analizlerin yapılabilmesi için temel önceliktir. Dolayısıyla bu alanlar disiplinler arası bilim dalları olarak değerlendirilmektedir.

Tezin amacı, uzaktan algılama ve coğrafi bilgi teknolojilerinin kullanılması ile madencilik faaliyetlerinin verimliliğini arttırmaktır. Nihai hedef, maden arama, uzaktan algılama ve coğrafi bilgi teknolojilerinde uzman bilgisine olan bağımlılığı en aza indirmektir. Amaç uzman bilgi birikimine gerek olmadan uydu görüntüleri kullanılarak potansiyel maden haritalarının hazırlanabilmesidir. Tez kapsamında uzaktan algılama ve makine öğrenmesi yöntemlerinin entegrasyonu ile bor maden sahalarının bulunması hedeflenmiştir.

1.2. Çalışmanın Özgün Değeri

Bor, günümüzde geniş kullanım alanına sahip, ülkemiz için stratejik önemi olan bir madendir. Uzaktan algılama analiz yöntemleri kullanılarak uydu görüntüleri ile bor madeni arama ve araştırma üzerine kısıtlı olsa da çalışmalar bulunmaktadır. Çalışmada bor minerallerini arama süreçlerini hızlandırmak ve iyileştirmek için uzaktan algılama teknolojilerinin gücünden yararlanılmıştır. Diğer çalışmalardan farklı olarak tezin özgün değeri, uzaktan algılama tekniklerinin yanı sıra makine öğrenmesi yöntemleri ile potansiyel maden haritaları hazırlanmasıdır. Çalışmada Google Earth Engine platformu üzerinde makine öğrenmesi yöntemleri ile bor minerallerinin sınıflandırılmasına çalışılmıştır. Makine öğrenmesi algoritmaları, büyük veri setlerini işlemek ve veri desenleri tanımlamak için kullanılmıştır. Tez kapsamında uzaktan algılama ve makine öğrenmesi yöntemlerinin entegrasyonu ile uydu görüntüleri üzerinde bor sahalarını tespit eden Bor Kâşifi adında bir araç geliştirilmiştir.

1.3. Yaygın Etki / Katma Değer

Çalışma uzaktan algılama teknikleri ile makine öğrenmesi yöntemlerini kullanarak uydu görüntüleri üzerinden potansiyel bor cevher tahmin haritalarının hazırlanmasında son kullanıcıya yönelik bir araç ortaya koymuştur. Bu yönüyle çeşitli madenlerin tespitinde ve potansiyel maden haritalarının hazırlanması için geliştirilecek araçlar için öncü niteliğindedir. Google Earth Engine üzerinde geliştirilen bu aracın madencilik çalışmalarına sağlayacağı katma değer oldukça yüksek olduğu düşünülmektedir. Borun nadir bulunan bir maden olması nedeni ile uzaktan algılama yöntemleri ile bor konusundaki çalışmalar oldukça azdır. Çalışmanın makine öğrenmesi alanlarına sağlayacağı katkı bor açısından bakıldığında oldukça özgündür.

1.4. Çalışmanın Kısıtlılıkları

Bor minerallerinin stratejik maden kategorisinde olması nedeni ile çalışmada doğruluk analizi için kullanılması düşünülen veri setlerine erişim sağlanamamıştır.

1.5. Literatür Özeti

Uzaktan algılama verileri, çeşitli uygulama alanlarında önemli bir kaynak olarak kullanılmaktadır. Bu alanlar arasında ormancılık, tarım, jeoloji, doğal kaynak yönetimi, arazi örtüsü tespiti ve arazi yönetim planları bulunmaktadır (Liu ve diğerleri, 2006; Rokade ve diğerleri, 2007; Hu ve diğerleri, 2010; Kunwar ve diğerleri, 2010; Royer ve diğerleri, 2011).

Uzaktan algılama teknolojileri, yeryüzünün görüntülenmesi ve önemli bilgilerin elde edilmesinde kritik bir kaynak olarak öne çıkmaktadır. Bu teknolojinin en önemli uygulama alanlarından biri, uydu görüntüleri aracılığıyla arazi örtüsü ve/veya arazi kullanımının belirlenmesi ve tematik haritaların üretilmesidir. Arazi örtüsü ve/veya kullanımının belirlenmesi, planlama süreçleri ve doğal çevrenin korunması açısından büyük önem taşımaktadır.

Uzaktan algılama teknolojileri, kent gelişimi, kaçak yapı tespiti, orman ve doğal yapılara verilen zararların belirlenmesi, afet bilgi sistemleri, kent bilgi sistemleri gibi birçok uygulama alanında kullanılabilmektedir (Silvestri ve Omri, 2008; Tang ve diğerleri, 2009; Jha ve diğerleri, 2009; Du ve diğerleri, 2009; Zhang ve diğerleri, 2010).

Uydu görüntüleri aracılığıyla arazi durumunun belirlenmesinde sıkça kullanılan bir yöntem, görüntü sınıflandırma işlemidir. Bu işlem, görüntüdeki çeşitli spektral özelliklere

sahip piksellerin, önceden belirlenen arazi örtüsü sınıflarına benzerliklerine göre sınıflandırılmasını içermektedir (Lillesand ve ark., 2008). Genel olarak, sınıflandırma işlemi, görüntü üzerinde belirli bir yansıtma ve parlaklık değerine sahip piksellerin arazi örtüsü sınıflarından birine atanması olarak tanımlanabilir (Campbell, 1996; Lillesand ve ark., 2008).

Bugüne kadar, uzaktan algılanmış görüntülerin sınıflandırılması ve tematik haritaların üretilmesi için birçok farklı yöntem geliştirilmiştir (Lu ve diğerleri, 2007; Tso ve ark., 2009; Du ve ark., 2012). Bu yöntemler, arazi örtüsü ve kullanımının detaylı analizine olanak sağlayarak, planlama ve doğal kaynak yönetimi alanlarında bilgi sağlama potansiyelini artırmaktadır.

Makine öğrenimi (MÖ), doğrusal olmayan sistemlerin regresyon ve/veya sınıflandırma (denetimli veya denetlenmeyen) için etkili bir ampirik yaklaşım sunmaktadır. Bu sistemler genellikle çok değişkenli olup, MÖ'nün bu tür karmaşık yapılarla başa çıkma yeteneği birçok alanda kanıtlanmıştır. Yer sisteminden (kara, okyanus ve atmosfer) arama algoritmalarına, bitki hastalık algılamasından yeni ürün oluşturmaya, önyargı düzeltmeye ve kod ivmesine kadar birçok uygulama MÖ'nün etkinliğini göstermiştir (Yi ve Prybutok, 1996; Atkinson ve Tatnall, 1997; Carpenter ve ark., 1997; Lary ve ark., 2004, 2009; Brown ve ark., 2008; Azamathulla, 2012; Zahabiyoun ve ark., 2013; Madadi ve ark., 2015).

MÖ, yapay sinir ağları (ANN), destek vektör makineleri (SVM), kendi kendini düzenleyen haritalar (SOM), karar ağaçları (DT), rastgele ormanlar gibi topluluk yöntemleri, beyin bulanıklığı (NF), genetik algoritmalar (GA), çok değişkenli uyarlanabilir regresyon spline'leri (MARS) gibi yaygın olarak kullanılan algoritmaları içermektedir (Shahin ve ark., 2001; Shahin ve Jaksa, 2005; Das ve Basudhar, 2008; Samui, 2008a,b; 2012; Azamathulla ve Wu, 2011; Azamathulla ve ark., 2011, 2012; Garg ve ark., 2014a,b,c).

Makine öğrenimi tabanlı yöntemler, genellikle bilim ve mühendislik problemlerinde yaklaşık 20 yıldır yaygın olarak kullanılmaktadır. Ancak, bu tekniklerin yerbilimleri ve uzaktan algılama alanlarındaki uygulamaları oldukça yeni ve sınırlıdır. Veritabanı üzerinden jeokomputasyon yöntemleri, bilinen cevher tipi konumları ile mekansal kanıtlar arasındaki ilişkileri değerlendirmek için iki veya çok değişkenli olabilir

(Tablo 1.1). Bu bağlamda, deneyim odaklı (knowledge driven) tek veya çok değişkenli ve veri odaklı (data driven) yaklaşımlarla ilgili çalışmaların bir derlemesi sunulmuştur.

Tahmin edici haritalar oluşturmak, araştırılan maden yataklarıyla mekansal ilişkilerin deneyim odaklı analizi veya veri odaklı jeokomputasyon yoluyla kanıtsal özelliklere ağırlık verilmesini içermektedir (Bonham-Carter, 1994; Carranza, 2008).

Tablo 1.1. *Referans çalışmalar*

Model/Metod	Referanslar
Boolean mantığı	Bonham-Carter (1994), Thiart ve De Wit (2000), Harris ve ark. (2001b)
İkili sınıf endeks kaplaması	Bonham-Carter (1994), Carranza ve ark. (1999), Thiart ve De Wit (2000)
Çok sınıflı endeks kaplaması	Bonham-Carter (1994), Harris ve ark. (2001b), Chica-Olmo ve ark. (2002), De Araújo ve Macedo (2002), Billa ve ark. (2004), Harris ve ark.(2008)
Bulanık mantık	An ve ark. (1991), Gettings ve Bultman (1993), Bonham-Carter (1994), D'Ercole ve ark. (2000), Groves ve ark. (2000), Knox-Robinson (2000), Porwal ve Sides (2000), Venkataraman ve ark. (2000), Carranza ve Hale (2001a), Porwal ve ark. (2003b), Tangestani ve Moore (2003), Ranjbar ve Honarmve (2004), De Quadros ve ark. (2006), Eddy ve ark. (2006), Harris ve Sanborn-Barrie (2006), Rogge ve ark. (2006), Nykänen ve Ojala (2007), Nykänen ve ark. (2008a,b), González-Álvarez ve ark. (2010)

Tablo 1.2. (Devam) Referans çalışmalar

Model/Metod	Referanslar
Kanıtsal inanç	Moon (1990, 1993), Chung ve Moon (1991), Moon ve ark. (1991), An ve ark. (1992, 1994a,b), Chung ve Fabbri (1993), Wright ve Bonham-Carter (1996), Tangestani ve Moore (2002), Chen (2004), Rogge ve ark. (2006)
Kanıt ağırlıkları analizi	Bonham Carter ve ark. (1988, 1989), Agterberg ve Bonham-Carter (1990, 2005), Agterberg ve ark. (1990, 1993a), Bonham-Carter ve Agterberg (1990, 1999), Bonham-Carter (1991, 1994), Agterberg (1992, 2011), Xu ve ark. (1992), Pan (1996), Rostirolla ve ark. (1998), Agterberg (1990, 1999), Bonham-Carter (1991, 1994), Agterberg (1992, 2011), Xu ve ark. (1992), Pan (1996), Rostirolla ve ark. (1998), Cheng ve Agterberg (1999). Raines (1999), Singer ve Kouda (1999), Carranza ve Hale (2000, 2002b,c), Pan ve Harris (2000), Venkataraman ve ark. (2000), Asadi ve Hale (2001), Mihalasky ve Bonham-Carter (2001), Harris ve ark. (2001b), Porwal ve ark. (2001,2006a, 2010a), Scott ve Dimitrakopoulos (2001), Tangestani ve Moore (2001), Agterberg ve Cheng (2002), Paganelli ve ark. (2002), Raines ve Mihalasky (2002), Harris ve ark. (2003), Carranza (2004, 2009b), Chen (2004), Chen ve ark. (2005), De Quadros ve ark. (2006). Daneshfar ve ark. (2006),

Tablo 1.3. (Devam) Referans çalışmaları

Model/Metod	Referanslar
Kanıt ağırlıkları analizi (devam)	Harris ve Sanborn-Barrie (2006), Nykänen ve Raines (2006), Nykänen ve Ojala (2007), Raines ve ark. (2007). Feltrin (2008), Ford ve Blenkinsop (2008a), Oh ve Lee (2008), Austin ve Blenkinsop (2009), Debba ve ark. (2009), Fallon ve ark. (2010)
Kanıtlayıcı inanç analizi	Chung ve Fabbri (1993), An ve ark. (1994b), Carranza ve Hale (2003), Carranza ve ark. (2005, 2008a,b,c, 2009), Carranza (2008, 2009a,2011), Carranza ve Sadeghi (2010)
Diskriminant analizi	Chung (1977), Prelat (1977), Bonham-Carter ve Chung (1983), Harris ve Pan (1999), Pan ve Harris (2000), Carranza (2008)
Karakteristik analiz	Botbol ve ark. (1977, 1978), McCammon ve ark. (1983, 1984), Harris (1984), Pan ve Harris (1992a, 2000)
Lojistik regresyon analizi	Chung (1978, 1983), Chung ve Agterberg (1980, 1988), Agterberg (1988, 1992, 1993), Sahoo ve Pvealai (1999), Pan ve Harris (2000), Harris ve ark. (2001b, 2006), Carranza ve Hale (2001b), Raines ve Mihalasky (2002), Harris ve ark. (2003). Agterberg ve Bonham-Carter (2005), Daneshfar ve ark. (2006), Nykänen ve Ojala (2007), Carranza (2008), Carranza ve ark. (2008a), Oh ve Lee (2008), Fallon ve ark. (2010). Porwal ve ark. (2010a), Chen ve ark.(2011)

Tablo 1.4. (Devam) Referans çalışmaları

Model/Metod	Referanslar
Uygunluk analizi	Pan (1993a,b,c), Pan ve Portefield (1995), Pan ve Harris (1992b, 2000), Rostirolla ve ark. (1998), Chen (2004)
Olabilirlik oranı analizi	Chung ve Fabbri (1993), Chung ve ark. (2002), Chung ve Keating (2002), Chung (2003), Harris ve Sanborn-Barrie (2006), Stensgaard ve ark. (2006), Oh ve Lee (2008)
Yapay Sinir Ağları	Singer ve Kouda (1996, 1997, 1999), Harris ve Pan (1999), Pan ve Harris (2000), Brown ve ark. (2000, 2003a,b), Bougrain ve ark. (2003), Harris ve ark. (2003), Porwal ve ark. (2003a, 2004), Rigol-Sanchez ve ark. (2003), Harris ve Sanborn-Barrie (2006), Behnia (2007), Skabar (2005, 2007a,b), Nykänen (2008), Pereira Leite ve De Souza Filho (2009a,b), Oh ve Lee (2010)
Bayesian ağ sınıflandırıcıları	Porwal ve ark. (2006b), Porwal ve Carranza (2008)

Kanıt özellikleri ile maden yatakları arasındaki mekânsal ilişkilerin deneyim odaklı analizi, bilinen türdeki maden yataklarının bulunduğu, jeolojik olarak izin verilen alanlarda veya daha az araştırılan (veya 'yeşil alanlar' olarak adlandırılan) bölgelerde uygun bir yaklaşımdır. 'Jeolojik olarak izin verici' ifadesi, bir alanın mevcut veya geçmiş jeolojik ayarı, belirli türde maden yatakları oluşumuna neden olabilecek süreçleri temsil ettiği anlamına gelir (Singer, 1993).

Kanıt özellikleri ile bilinen cevher tipi yerler arasındaki mekânsal ilişkilerin veri odaklı jeokomputasyonu, jeolojik açıdan izin verici alanlarda orta dereceden iyi örneklenmiş (veya 'kahverengi alanlar' olarak adlandırılan) mineralize peyzajları temsil

eden alanlarda uygun bir yaklaşımdır. Bu durumda amaç, yeni keşfedilmemiş cevherlerin daha ileri düzeyde araştırılmasıdır.

Veri odaklı yöntemler arasında yalnızca kanıtsız inanç modellemesi, mineral sistemleri bilgisini entegre etmek veya cevherleşmenin jeolojik kontrollerini değiştirmek için kullanılabilir (Carranza, 2008; Carranza ve ark., 2008b).

Bulanık kütle modellemesi ağırlıkları (Cheng ve Agterberg, 1999), veri tabanlı bulanık modelleme (Luo ve Dimitrakopoulos, 2003; Porwal ve ark., 2003b; Zuo ve diğerleri, 2009b) ve nöro bulanık modelleme (Porwal ve diğerleri, 2004), maden yatakları ile keşfedilen hedeflerin jeokomputasyonel modellemesinde kanıt özellikleri arasındaki ampirik mekansal ilişkileri ve mineral sistemleri hakkındaki kavramsal bilginin kullanımını optimize etmek için önerilmiştir.

Tahmini haritaları oluşturmak ve/veya bütünleştirmek için kullanılan her yöntem, maden yatağı oluşumundaki jeolojik süreçlerin etkileşimleriyle ilgili sistemik hatalar içermektedir. Ayrıca, arama hedeflerinin jeokomputasyonel modellemesinde kullanılan her giriş jeosistem uzamsal veri seti veya eşlenen kanıt özellikleri, keşfedilen ve keşfedilmemiş maden yatakları dağılımında parametrik hatalar içermektedir.

Tahmini modellemede bu hatalar kaçınılmazdır. Ancak, bu tür hatalar nihayetinde keşif hedeflerinin tahmini haritasına eklendiğinden, model kalibrasyonu için önlemler uygulamak ve mümkünse, jeokomputasyon analizinin her adımında model geçerliliği yoluyla hataları azaltmak zorunludur. Model kalibrasyonu ve model doğrulama, aranan türün keşfedilmemiş cevher yatakları keşfine fırsat sağlamak amacıyla keşif hedeflerinin mümkün olan en iyi tahmini haritasını elde etmeyi amaçlamaktadır.


2. KURAMSAL TEMELLER

2.1. Uzaktan Algılama

Bulunduğumuz ortamı, nesne veya nesnelerin algılanmasını duyu organlarımız aracılığıyla gerçekleştirmekteyiz. Duyu organlarımız aracılığıyla algılanan bu veriler beyin tarafından işlenerek anlamlı bir hale getirilmektedir. Görme duyu organımız olan gözümüz, etrafta bulunan nesneler ve ortam ile ilgili bilgileri fiziksel bir temas olmadan ışık kaynağından yayılan ışık enerjisine nesnelerin ve ortamın verdiği tepkileri algılayarak, nesneler ve ortam hakkında bilgi edinilmesini sağlamaktadır. Benzer şekilde duyma duyu organımız olan kulaklarımızda bir ses kaynağından çıkan seslerin herhangi bir fiziksel temas olmadan algılanması sağlamaktadır. Bir ısı kaynağının yaydığı ısı enerjisinin herhangi bir fiziksel temas olmadan ortamın veya bir nesnenin sıcaklığı tenimiz tarafından algılanabilmektedir. Temelde bu duyuların fonksiyonel olarak ortak özelliği bir nesne veya ortam hakkında bilginin bir enerji kaynağı tarafından sağlanan enerjiye nesne ve ortamın vermiş olduğu tepkileri herhangi fiziksel bir temas olmadan algılamasıdır. Çevremizde bulunan nesneleri duyularımızla başarılı şekilde algılamamız, bilim insanlarını çevreyi ve nesneleri algılaması için duyulara benzer şekilde çalışan algılayıcılar geliştirmeye yöneltmiştir. Bu sayede nesneler ve ortamın bir enerji kaynağına verdiği tepkileri fiziksel bir temas olmadan bilgi edilmesini sağlayan algılayıcıların gelişmesiyle uzaktan algılamanın temelleri atılmış oldu.

Uzaktan algılama için literatürde birçok tanımlama yapılmasına karşın, fiziksel bir temas olmadan nesne/nesneler hakkında bilgi edinilmesi/değerlendirilmesi olarak genelleştirilebilir. Uzaktan algılama yapılabilmesi için temelde; bilgi toplanması istenen nesnenin/hedefin belirlenmesi, kullanılacak enerji kaynağının belirlenmesi, nesnelerin bu enerji kaynağına verdiği iletim/tepki/yansıma algılayıcı tarafından ölçülmesi ve bu ölçümlerin kaydedilmesi adımlarından oluşmaktadır.

Uzaktan algılama için enerji kaynağı algılayıcılardan bağımsız olabileceği gibi, algılayıcılar tarafından da sağlanabilir. Uydu fotoğraflarının çekilmesi pasif algılama sistemine, lidar aracılığıyla bilgi toplanması ise aktif algılama sistemlerine örnektir.



Şekil 2.1. Pasif uzaktan algılama işleyişi


Pasif uzaktan algılama sistemlerinin genel işleyişi Şekil 2.1’de görüldüğü üzere; enerji kaynağı olarak güneşin (1) enerjisini ışıma yoluyla iletmekte (2), hedef olarak belirlenen nesne/nesnelerin (3), elektromanyetik ışıma yoluyla verdikleri tepkilerin (yayılan/yansıyan) (4) algılayıcılara sahip gözlem uyduları (5) tarafından ölçülmesi, ölçülerin verilerin kaydedilmesi ve işlenmesi için verilerinin (6) yer istasyonuna gönderilmesi (7), ilgili veriler işlenmek ve kaydedilmek üzere iletilmesi (8), ölçüm verilerinin düzeltme, işleme ve analiz edilerek uygulamalar için hazır hale getirilmesi, kayıt altına alınması adımlarını içermektedir.

2.1.1. Elektromanyetik ışıma

Uzaktan algılamada yoğun şekilde kullanılan temel enerji kaynağımız olan Güneş, dünyamıza enerjisini elektromanyetik ışıma (elektromanyetik adyasyon-EMR) yoluyla taşımaktadır. En çok bilinen formu görünür ışık olmasına karşın, radyo dalgaları, mikrodalgalar, X-ışınları gibi birçok formu bulunmaktadır. Elektromanyetik ışıma dalga ve tanecik olmak üzere iki karakteristik özelliğini taşımaktadır. Elektromanyetik ışıma, yayılım için dalga modeli karakteristiği gösterirken, soğurma ve emisyon için parçacık modeli karakteristiği göstermektedir. Geliştirilen bu modele göre ışık, dalga ve madde özelliği gösteren fotonlardan meydana gelmektedir.

Elektromanyetik ışımanın yayılımı temel dalga teorisiyle açıklanmakta olup, Şekil 2.2’de görüldüğü üzere, elektromanyetik dalga; elektrik (E) ve manyetik (M) olmak üzere yayılma eksenine ve birbirine dik iki alandan oluşmaktadır. Bu alanlarda ışık hızında


hareket eden aynı fazda yayılan sinüzoidal yapıdaki dalgaların her ikisi de yayılma yönüne dik açı yapmaktadırlar.



Şekil 2.2. Elektromanyetik dalga parametreleri (Tempfli, et al., 2009)


Elektromanyetik dalgalarda dalga boyu (λ) iki tepe noktası arasındaki uzaklığı, frekans bir saniyede geçen dalga sayısını, boşluktaki hızları aynı ve ışık hızını (3×10^8 m/s) ve genliği elektrik vektörünün en uzun olduğu uzaklığı ifade etmektedir.

Elektromanyetik ışıınının, enerji ve madde ile olan ilişkisi parçacık modeliyle açıklanmaktadır. Buda foton adı verilen parçacığın elektromanyetik dalgaının frekansı ile ilişkili bir enerjisi olduğunu ve bu enerji $E=hf$ ilişkisiyle bulunmaktadır. Bu eşitlikte E fotonun enerjisini, h Planck sabitini, f dalgaının frekansını göstermektedir. Ayrıca dalga boylarıyla ters, frekanslarıyla doğru orantılı olarak geçtikleri ortama enerji aktarmaktadır. Şekil 2.3’de görüldüğü üzere Elektromanyetik ışıma enerjisi dalga boyu azaldıkça, artmaktadır.



Şekil 2.3. Elektromanyetik dalganın enerji ve dalga boyu ilişkisi (<http-1>)

Elektromanyetik tayf veya elektromanyetik spektrum (EMS) bütün elektromanyetik dalgaları barındıran bir ölçektir, çeşitli uzunluklarda dalga boyları ve frekanslara göre sınıflandırılmıştır. Şekil 2.4’de görüldüğü üzere elektromanyetik tayfta bulunan sınıflandırmalar; radyo, mikro, kızılötesi, görünür, mor ötesi, x-ışını, gama ışını olarak adlandırılmıştır.



Şekil 2.4. Elektromanyetik tayf (Rayar et al., 2023)

2.1.2. Atmosferik etki

Uzaktan algılama sistemleri, yeryüzünü ve atmosferi inceleyerek çeşitli veriler toplar. Bu verilerin doğruluğu ve kalitesi atmosferik etkilerden önemli ölçüde etkilenmektedir. Atmosfer, güneşten gelen elektromanyetik enerjinin yeryüzüne ulaşmadan önce geçtiği ortamdır ve bu süreç sırasında enerji, atmosferi oluşturan bileşenlerle etkileşime girerek değişime uğrar.


Atmosferik etkiler iki ana tipte kategorize edilebilir: saçılma ve soğurma. Saçılma, elektromanyetik radyasyon atmosferdeki gaz molekülleri, toz parçacıkları ve su damlacıkları gibi parçacıklar tarafından yansıtıldığında veya kırıldığında meydana gelir. Bu işlem sırasında enerji yön değiştirir ve dalga boyuna bağlı olarak farklı şekilde dağılır. Rayleigh saçılması, radyasyonun dalga boyu saçılan parçacıklardan çok daha büyük olduğunda meydana gelir ve gökyüzünün mavi görünmesine neden olur. Mie saçılması, ışığın dalga boyu kabaca atmosferdeki parçacıkların boyutuna eşit olduğunda meydana gelir ve tipik olarak puslu atmosfer koşullarını etkiler. Seçici olmayan saçılma, parçacıklar radyasyonun dalga boyundan çok daha büyük olduğunda meydana gelir ve çok tozlu koşullarda belirgin hale gelir.

Atmosferik soğurma, elektromanyetik enerjinin atmosferin su buharı, karbondioksit ve ozon gibi bileşenleri tarafından emilmesini içerir. Bu bileşenler enerjiyi belirli dalga boylarında emerek yeryüzüne ulaşmasını engeller. Bununla birlikte, atmosferin enerjinin minimum etkileşimle geçmesine izin verdiği ve "atmosferik pencereler" olarak bilinen belirli dalga boyu aralıkları vardır. Bu pencereler elektromanyetik spektrumun ultraviyole, görünür, termal, mikrodalga ve radar bölgelerinde mevcuttur. Bu bölgelerde enerji atmosferden geçebilir ve minimum emilim ve saçılma ile yeryüzüne ulaşabilir.

Atmosferin etkileri uzaktan algılama verilerinin kalitesini doğrudan etkiler. Saçılma, sensörlerin enerjinin bazı kısımlarını kaçırmasına neden olarak görüntülerde kontrast kaybına yol açabilir. Soğurma, belirli dalga boylarında enerji kaybına yol açarak verilerde boşluklara neden olur. Bu nedenle, uzaktan algılama verilerini doğru bir şekilde yorumlamak için atmosferik etkileri dikkate almak ve gerekli düzeltmeleri uygulamak çok önemlidir.

2.1.3. Atmosferik pencereler ve nesnelerin imzası

Elektromanyetik enerji yeryüzündeki bir nesneye veya yüzeye ulaştığında üç temel etkileşim meydana gelir: emilim, yansıma ve iletim (Şekil 2.5).



Şekil 2.5. Elektromanyetik enerjinin üç temel etkileşimi (Çölkesen, 2015)


Bir nesneye gelen enerji (I) emilebilir (A), iletilebilir (T) veya yansıtılabilir (R). Bu ilişki enerji dengesi denklemi ile ifade edilir:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (2.1)$$

- $E_I(\lambda)$ gelen toplam radyasyondur,
- $E_R(\lambda)$ yansıyan enerjidir,
- $E_A(\lambda)$ absorbe edilen enerjidir,
- $E_T(\lambda)$ iletilen enerjidir.

Her nesne veya yüzey enerji ile etkileşime girdiğinde kendine özgü benzersiz spektral imzalar oluşur. Bu imzalar uzaktan algılamada nesneleri ayırt etmek için gereklidir. Uzaktan algılama sistemleri, seçilen dalga boyu aralıklarında yansıyan ve yayılan enerjideki değişimleri yakalayıp farklı nesnelerin spektral özelliklerine göre tanımlanmasını ve analiz edilmesini sağlar.

Örneğin, bitki örtüsünün spektral yansımaları pigment konsantrasyonu, yaprak yapısı ve su içeriğine göre değişir. Toprağın spektral özellikleri nem içeriği, organik madde, yüzey pürüzlülüğü ve demir oksit varlığı gibi faktörlerden etkilenir. Su kütleleri, özellikle gelen enerjinin çoğunu emdikleri yakın ve orta kızılötesi bölgelerde farklı spektral özelliklere sahiptir, bu da onları diğer nesnelerden kolayca ayırt edilebilir hale getirir (Şekil 2.6).



Şekil 2.6. Toprak, bitki ve su için spektral yansıtım grafiği (Lillesand ve ark, 2004)

Atmosferik etkileri ve enerji-nesne etkileşimlerini anlamak, doğru uzaktan algılama veri analizi için çok önemlidir. Spektral imzalardaki değişimleri yakalayıp analiz ederek, uzaktan algılama sistemleri ayrıntılı çevresel gözlemler ve değerlendirmeler sağlayabilir. Bu bilgi, uzaktan algılama teknolojilerinin güvenilirliğini artırarak daha doğru ve anlamlı veri yorumlamasına olanak tanır.

2.1.4. Uzaktan algılamada çözünürlük


Uzaktan algılamada çözünürlük, bir görüntüleme sisteminin yakalayabildiği ayrıntı düzeyini ifade eder. Uzaktan algılamada konumsal, spektral, radyometrik ve zamansal olmak üzere dört temel çözünürlük türü vardır.

- Konumsal çözünürlük
- Spektral çözünürlük:
- Radyometrik çözünürlük:
- Zamansal çözünürlük:

Her çözünürlük türü farklı uygulamalar için çok önemlidir ve çeşitli doğal ve insan yapımı ortamları etkili bir şekilde izleme, analiz etme ve yönetme becerisini geliştirir.

2.1.4.1 Konumsal çözünürlük


Sensörün anlık görüş alanı tarafından belirlenen, bir sensörün tespit edebileceği en küçük nesneyi ifade eder. Daha yüksek uzamsal çözünürlük, daha ince ayrıntılar ve daha küçük piksel boyutları anlamına gelir ve nesneler arasında daha net ayrım yapılmasını sağlar. Örneğin, yüksek uzamsal çözünürlüğe sahip bir görüntü daha küçük piksel boyutlarına sahip olacak ve Dünya yüzeyinin daha ayrıntılı gözlemlenmesine olanak sağlayacaktır. Tersine, düşük uzamsal çözünürlük daha büyük piksellerle sonuçlanır, bu da daha ince ayrıntıları gizleyebilir ve farklı nesneler arasında ayrım yapmayı zorlaştırabilir. Uzaktan algılamada bir sensörün veya alıcının anlık görüş alanı açısaldır; yeryüzündeki karşılığı da uydu yüksekliğine göre değişebilir (Şekil 2.7). Bu büyüklük aynı zamanda pikselin boyutuna eşittir. Anlık görüş alanı açısal ve uzunluk olarak iki şekilde ifade edilebilir.



Şekil 2.7. Uydu anlık görüş alanı

Şekildeki X-Y noktaları arasındaki mesafe anlık görüş alanını temsil eder ve bu uzaklık, uydu görüntüsünde yaklaşık olarak bir piksele karşılık gelir. Bu uzunluk,

algılayıcı tarafından yeryüzünde ayırt edilebilen en küçük uzunluktur. Şekil 2.8’de, aynı bölgeye ait farklı konumsal çözünürlüğe sahip uydu görüntülerine ait örnekler bulunmaktadır. Şekilde konumsal çözünürlüğün artmasıyla birlikte, görüntüdeki objelerin birbirinden ayırt edilebilirliğinin arttığı ve yorumlanma açısından daha kolay hale geldiği açıkça görülmektedir. Aynı şekilde çözünürlük azaldıkça, objelerin ayırt edilebilmesi ve görüntünün analizi zorlaşmaktadır.



Şekil 2.8. Konumsal çözünürlük

2.1.4.2 Spektral çözünürlük

Sensörün elektromanyetik spektrumun belirli dalga boylarını yakalama yeteneğini gösterir. Bu çözünürlük, genel olarak kullanılan bantların sayısını ve genişliğini içerir. Daha yüksek spektral çözünürlük, dar dalga boyu aralıklarının algılanmasına olanak tanıyarak malzemelerin spektral imzalarına göre hassas bir şekilde tanımlanmasına yardımcı olur.

Spektral özellik, her cismin yansımaya, yayılma, geçirgenlik ve soğurma özellikleri olarak ifade edilebilir. Algılayıcıların tasarımı, bu spektral özelliklerdeki değişiklikleri tespit edebilecek ve istenen ayrımları yapabilecek şekilde düzenlenmiştir. Yeryüzündeki cisimlerin spektral özellikleri ile kendi özellikleri arasında güçlü bir ilişki bulunmaktadır.

Her spektral bant, elektromanyetik spektrumun belirli bir bölümüne duyarlıdır ve bu bölgeler başlangıç ve bitiş dalga boyları, merkez frekans veya bant genişliği şeklinde ifade edilir. Uzaktan algılama aletlerinin spektral ayırma gücü, kullanılan bant genişliği ile belirlenir. Daha iyi spektral çözünürlük, özellikle belirli bir kanal veya bant için daha dar dalga boyu aralığı anlamına gelir. Teorik olarak, spektrum ne kadar çok ve küçük parçaya ayrılırsa, spektral ayırma gücü de o kadar artar. Bu nedenle en iyi çözüm, istenilen ayrımı yapmak için en az bantı kullanmaktır.

2.1.4.3. Radyometrik çözünürlük

Piksellerin yapısal özellikleri, bir görüntünün uzaysal yapısını tanımlarken, radyometrik özellikler, bir görüntünün elde edilen elektromanyetik enerji miktarına olan duyarlılığını ifade eder. Yeryüzündeki her bir piksele karşılık gelen alanlardan yansıyan ışığın şiddeti, algılayıcılar tarafından değişik derecelerde kaydedilir. Bu, alıcının radyometrik çözünürlüğü olarak adlandırılır. Radyometrik çözünürlük, objeleri tanımlamak ve ayırt etmek için kullanılan toplam renk tonu sayısını belirtir. Derecelendirme veya tonlama ne kadar yüksekse, ayırt etme gücü de o kadar yüksek olur.

Radyometrik çözünürlük, bir uzaktan algılama sisteminde siyah ile beyaz renkleri arasındaki gri tonlarını ölçen bit olarak adlandırılan bir ölçme değeri kullanır. 1 bitlik sistem sadece iki gri düzeyini ölçebilir ($2^1=2$). Örneğin, 8 bitlik bir sensör $2^8=256$ yoğunluk seviyesini ayırt edebilirken, 12 bitlik bir sensör $2^{12}=4096$ seviyeyi ayırt edebilir.

2.1.4.4. Zamansal çözünürlük

Zaman içindeki değişimleri gösterme yetenekleri, birçok nesne için ayırt edilebilirliği artırıcı bir etken olarak önemlidir. Görüntülerin farklı zamanlarda, değişik zaman aralıklarıyla elde edilmesi, çok zamanlı uydu görüntülerinin elde edilmesine olanak tanır. Burada, iki görüntü arasındaki zaman farkı ve alım zamanı önemlidir. Uygun zaman aralığı, amaca bağlı olarak yıl, mevsim, birkaç gün veya hafta olabilir. Uzaktan algılamanın önemli işlevlerinden biri, zaman içindeki değişimleri izlemektir. Bu nedenle algılayıcı sistemin ayırma gücü, özelliklerin belirlenmesinde zamanla ilgili ayırma gücünün sistem için belirleyici bir özellik olduğu bir parametre olmaktadır (Ayhan, 2003). Uzaktan algılama sistemleri için zamansal çözünürlük, aynı alan için verilerin hangi sıklıkta elde edildiğini belirtir (Gibson, 2000). Bir alıcının belirli bir noktayı ardışık olarak algılayabileceği zaman dilimini ifade eder. Örneğin Landsat4, Landsat5 ve Landsat6 uyduları 16 günde bir aynı noktadan geçerken, Sentinel-2 uydusu aynı noktayı her 5 günde bir tekrar ziyaret eder.

2.1.5. Uzaktan algılamada sınıflandırma

Uydu görüntülerinin sınıflandırılmasından elde edilen tematik bilgiler, coğrafi bilgi sistemleri için önemli bir veri kaynağıdır. Bu nedenle, sınıflandırma işlem adımları ve kullanılan yöntemler titizlikle analiz edilmeli ve seçilmelidir. Sınıflandırma sonucunda yeryüzünün farklı özelliklerini temsil eden tematik haritalar elde edilir. Uydu

görüntülerindeki mekânsal-spektral bilginin karmaşıklığını yönetilebilir sayıda sınıfa indirgeyen bu haritalar, bu görüntülerin yorumlanması ve analizi için çok önemlidir.

Sınıflandırma tekniklerinin madencilik ve jeoloji alanlarında kapsamlı uygulama alanları bulmuştur. Uzaktan algılama verileri maden arama ve cevher yatağı haritalama için hayati önem taşımaktadır. Uydu görüntüleri ve hava fotoğrafları kullanılarak, Dünya yüzeyindeki mineral bileşimleri ve jeolojik yapılar tanımlanabilmektedir. Bu yöntemler, maden yataklarının tespiti, rezervlerin değerlendirilmesi ve çevresel etkilerin izlenmesi için kritik veriler sağlar. Ayrıca, sınıflandırma teknikleri jeolojik haritalama ve topografik analizi geliştirerek daha ayrıntılı ve doğru bilgiler sağlar. Bu işlemler, görüntülerden elde edilen spektral ve uzamsal bilgilerin yanı sıra bölgedeki diğer yardımcı verileri de kullanır.

Spektral Tabanlı Sınıflandırma görüntü verisinin her bir spektral banttaki ışıının değerleri üzerinden yapılan sınıflandırmadır. Mekânsal Tabanlı Sınıflandırma ise görüntü verisine ait piksellerin komşuluk, geometrik yakınlık ve doku gibi mekânsal ölçütleri temel alan kriterlere göre sınıflandırmadır.

Uzaktan algılanan görüntülerin sınıflandırılması, çok sayıda faktörün değerlendirilmesini gerektiren karmaşık prosedürleri içerir. Sınıflandırma işlemi sırasında, uygun bir sınıflandırma yaklaşımının seçilmesi, sınıflandırıcının eğitilmesi için örnek piksellerin belirlenmesi, görüntünün ön işleminden geçirilmesi, özelliklerin çıkarılması, uygun bir sınıflandırma algoritmasının seçilmesi, sınıflandırma sonrası işlemlerin gerçekleştirilmesi ve doğruluk analizinin yapılması temel adımlar arasında yer alır. Kullanıcı gereksinimleri, çalışma alanının ölçeği, ekonomik koşullar ve analistin deneyimi gibi faktörler uydu görüntüsünün seçimini, sınıflandırma yaklaşımının/algoritmasının belirlenmesini ve sınıflandırma sonuçlarının kalitesini önemli ölçüde etkilemektedir (Lu ve Weng, 2007)

Sınıflandırma için iki temel yaklaşım yaygın olarak kullanılmaktadır: denetimli ve denetimsiz sınıflandırma. Denetimli sınıflandırmada, spektral ayırt edilebilirliği incelemek için farklı spektral grupları temsil eden örnekleme alanları kullanılır. Tersine, denetimsiz sınıflandırma spektral olarak farklı sınıfları tanımlar ve bunlardan bilgi türetir.

2.1.5.1 Uzaktan algılamada sınıflandırmayı etkileyen faktörler

Genel olarak sınıflandırmada, kategorilere ait özellikler arasındaki karışım nedeniyle birbirlerinden ayırt edilebilirliği etkileyen başlıca dört faktör vardır:

- Topoğrafya ve aydınlanma koşulları
- Atmosferik değişkenlik
- Sensör kalibrasyon değişiklikleri
- Sınıf karışımları

olarak sıralanabilir. Sınıfları temsil eden veri özellikleri genellikle tek vektörler yerine dağılımlar olarak gösterilir. Multispektral görüntülerin yüksek doğrulukta sınıflandırılması, sınıf özellikleri arasındaki karışımın yönetilmesine bağlıdır ve bunu ele almak için ayırt edilebilirliğe bağlı çeşitli yöntemler geliştirilmiştir.

Piksel Tabanlı Sınıflandırma; benzerlik fonksiyonlarına dayalı olarak her piksele tek bir kategori atamaktadır. Bu yöntem karışık piksellerden kaynaklı olarak sınırlı ve gerçek dünya koşullarını her zaman doğru yansıtmamaktadır.

Alt Piksel Sınıflandırması; karışım bileşenlerini belirlemek için çoklu spektral algılayıcılardan alınan verileri kullanarak piksellerin genellikle birden fazla spektral kategori içerdiğini kabul etmektedir. Bu yöntem, benzerliğe dayalı olarak birden fazla sınıfa üyelik değerleri atamaktadır.

Alan Tabanlı Sınıflandırma; tek tek pikseller yerine tüm alanları sınıflandırmaya odaklan sınıflandırmadır. Mekânsal nesne sınırları hakkında önden bilgi verilerek tanımlanan bilgiler ışığında sınıflama yapmaktadır. Alanları karakterize etmek için ortalama ve standart sapma gibi özellikler kullanmaktadır.

Nesne Tabanlı Sınıflandırma; piksel gruplarından spektral, doku ve bağlamsal bilgileri kullanır. Bu yöntem yüksek çözünürlüklü görüntüler için uygulanır ve daha doğru ve anlamlı sınıf dağılımları sağlayabilir. Nesneler, homojenlik kriterlerine dayalı segmentasyon algoritmaları kullanılarak oluşturulmaktadır.

Sınıflandırma işlemi için hangi algoritma kullanılırsa kullanılsın denetimli ve denetimsiz olmak üzere iki temel yaklaşım vardır. Denetimli sınıflandırma yaklaşımında istenen sınıfları temsil eden öncül tematik bilgi vardır ve bunlara eğitim verisi denir.

Diğer bir ifade ile her bir örüntü için karar fonksiyonlarına göre atanacağı olası sınıflar önceden belirlidir. Buna göre eğitim verileriyle belirlenen karar fonksiyonlarıyla özellik uzayını oluşturan her bir örüntü bilinen bir sınıfa atanır.

Uzaktan algılamada sınıflandırma uydu görüntülerinden tematik bilgilerin elde edilebilmesi için temel bir tekniktir. Bir görüntüdeki her pikseli orman, su veya maden alanı gibi belirli bir arazi örtüsü sınıfına ayırmamıza olanak tanır. Sınıflandırma işlemi için hangi algoritma kullanılırsa kullanılsın denetimli ve denetimsiz olmak üzere iki temel yaklaşım vardır (Sunar F. ve Özkan C., 2018).

Denetimli sınıflandırma, arzu edilen ilgi sınıfları hakkında ön bilgidен yararlanır. Bu bilgi, önceden tanımlanmış her sınıf için temsili örneklerden oluşan eğitim verileri biçiminde somutlaştırılmıştır (Richards & Jia, 2013). Bu eğitim örnekleri, her sınıfla ilişkili spektral özellikleri öğrenmek amacıyla sınıflandırma algoritması için bir referans görevi görür. Algoritma daha sonra eğitim verilerinden türetilen karar fonksiyonlarını kullanarak görüntüdeki her pikseli eğitim örneklerine olan spektral benzerliğine göre sınıflandırır (Lu et al., 2004).

Denetimli sınıflandırmanın başarısı, eğitim verilerinin kalitesine ve temsil edilebilirliğine bağlıdır. Kapsamlı saha kampanyaları veya mevcut tematik haritalar genellikle her sınıftaki doğal değişkenliği kapsayan eğitim örneklerini toplamak için kullanılır (Jensen, 2016).

Denetimli sınıflandırmanın aksine, denetimsiz sınıflandırma önceden tanımlanmış sınıflar veya eğitim verileri olmadan çalışır. Bunun yerine algoritma, görüntünün kendisindeki doğal spektral özellikleri analiz eder. Benzer spektral imzalara sahip pikselleri kümeler halinde gruplamak için kullanılır (Lu et al., 2004 & Jensen, 2016). Küme sayısı kullanıcı tarafından önceden belirlenebilir veya algoritma istatistiksel kriterlere göre en uygun sayıyı belirleyebilir.

Kümeleme adımını takiben analist, her kümenin spektral özelliklerini yorumlar ve çalışma alanı hakkındaki bilgilerine ve topografik haritalar, hava fotoğrafları veya saha araştırmaları gibi dış bilgi kaynaklarına dayanarak anlamlı sınıf etiketleri atar (Jensen, 2016). Burada analistin uzmanlığı, spektral kümeleri gerçek dünyadaki arazi örtüsü sınıflarına doğru bir şekilde bağlamada çok önemli bir rol oynar.

Denetimli ve denetimsiz sınıflandırma arasındaki seçim, analizin belirli hedeflerine ve önceki tematik bilgilerin mevcudiyetine bağlıdır. Denetimli sınıflandırma, belirli arazi örtüsü sınıflarının öncelikli olduğu ve yüksek sınıflandırma doğruluğunun önemli olduğu durumlarda üstün başarı gösterir. Ancak, eğitim verilerinin toplanması ve hazırlanmasında ciddi bir ön çaba gerektirir. Bunun tersine, denetimsiz sınıflandırma, keşifsel analiz veya verilerdeki beklenmedik kalıpların belirlenmesi için yararlı olabilecek hızlı bir yaklaşımdır (Tout & Littin, 2004). Ancak spektral kümelerle anlamlı sınıf etiketleri atamak daha fazla işlem sonrası çaba gerektirebilir.

Hem denetimli hem de denetimsiz sınıflandırma, uzaktan algılama araç kutusundaki değerli araçlardır. Denetimli sınıflandırma, yüksek doğrulukla hedeflenen analiz sunarken, denetimsiz sınıflandırma, spektral modellerin veri odaklı bir şekilde keşfedilmesini sağlar. Uygun yaklaşımın seçilmesi çalışmanın spesifik hedeflerine ve mevcut kaynaklara bağlıdır.

Denetimsiz sınıflandırma yaklaşımında ise öncül herhangi bir tematik bilgi yoktur. Diğer bir ifade ile sınıfların ne olduğu ve örüntülerin hangi sınıfa atanacağı bilgisi bulunmamaktadır. Örüntüler belirli bir metriğe göre doğal olarak kümelenirler. Doğal spektral grupların oluşturduğu bu kümeler, daha sonra arazi incelemeleriyle veya topoğrafik haritalar ve hava fotoğrafları kullanılarak etiketlenir.

2.1.6. Uzaktan algılamada sahte renk bileşimleri (FCC)

Uzaktan algılama, insan gözünün görünür aralığının ötesinde geniş bir spektrumda yansıyan ve yayılan enerjiyi yakalayarak yeryüzüne benzersiz bir pencere sağlar. Sınırlı bir dalga boyu bandını renk olarak algılamak, uydulardaki ve uçaklardaki sensörler kızılötesi, morötesi ve diğer bölgelerdeki bilgileri kaydeder. Uzaktan algılamanın temel taşı tekniği olan sahte renk bileşimleri (False Color Composite, FCC), çıplak gözle görülmeyen özellikleri görselleştirmek ve sahnenin yorumlanabilirliğini geliştirmek için bu çok bantlı verileri kullanır.

Gerçek renkli görüntünün aksine, sahte renkli bileşimler, gerçekliğin doğrudan temsili değildir. Multispektral verilerden belirli görüntü bantlarının, genellikle bir görüntüyü görüntülemek için kullanılan kırmızı, yeşil ve mavi (RGB) kanallara atanmasıyla oluşturulur (Lu et al., 2004). Temel olarak bu işlem, verilere renkleri yeniden atar ve görünmez bantlardaki farklı spektral özelliklere sahip özelliklerin renkli olarak

görselleştirilmesine olanak tanır. Bu yöntem, uzaktan algılama analizi için güçlü ve önemli avantajlar sağlar.

Gelişmiş özellik görselleştirme belirli bantların RGB kanallarına atanması, bu bantlarda zıt yansıma özelliklerine sahip özelliklerin vurgulanmasına olanak tanır. Örneğin, sağlıklı bitki örtüsü yakın kızılötesi (Near InfraRed-NIR) bölgede yüksek yansıma sergiler ancak kırmızı bantta güçlü bir şekilde soğurur. NIR'ı kırmızıya ve kırmızıyı yeşile atayan sahte renk bileşimi, sağlıklı bitki örtüsünün parlak kırmızı görüldüğü çarpıcı bir görüntü oluşturarak onu diğer arazi örtüsü sınıflarından kolayca ayırt edilebilir hale getirir (Jensen, 2016).

Geliştirilmiş spektral ayırım tek bantlarda ayırt edilemeyen özellikler arasındaki ince spektral farklılıklar, sahte renkli bir kompozitte vurgulanabilir. Bu, farklı bitki örtüsü türleri, mineraller veya kentsel alanlar gibi arazi örtüsü sınıflarını benzersiz spektral imzalarına dayalı olarak doğru bir şekilde tanımlama ve haritalama yeteneğini geliştirir.

Hedefli analiz araştırma hedeflerine bağlı olarak, ilgilenilen özelliklerin görselleştirilmesini optimize etmek için belirli bant kombinasyonları seçilebilir. Örneğin, demir oksit mineralleri üzerinde çalışan bir jeolog, bu minerallerin tanımlanmasına ve haritalanmasına yardımcı olan, demir emilim özelliklerine duyarlı, sahte renkli kompozit vurgulayıcı bantlar kullanabilir (Tout & Littin, 2004).

Sahte renk bileşimleri uzaktan algılama analizi için güçlü bir araç sunarken, dikkate alınması gereken bazı sınırlamaları vardır. Örneğin tek bir RGB kanalına birden fazla bant atamak, bireysel bantları analiz etmeye kıyasla kaçınılmaz olarak bazı spektral bilgilerin kaybına neden olur (Jensen, 2005).

Sahte renk bileşimlerinde bant seçimi yorumlamada öznellik sağlamaktadır. Bant seçimi ve sıralaması yüzeylerin nasıl görüldüğünü önemli ölçüde etkileyebilir. Çalışma hedeflerinin ve ilgilenilen yüzeylerin spektral özelliklerinin dikkatli bir şekilde değerlendirilmesi, en etkili bant kombinasyonlarının seçilmesi için çok önemlidir (Lillesand & Kiefer, 2004).

Sahte renk bileşimleri doğal renk gösteriminden farklı olduğu için, yorumlanması uzaktan algılama görüntülerine aşina olmayanlar için eğitim ve deneyim gerektirebilir (Mather, 2014). Sahte renk bileşimleri, uzaktan algılama analizleri için temel bir araçtır. Multispektral verilerin gücünden yararlanarak ve görsel görüntüyü değiştirerek,

araştırmacılara insan gözüyle görülmeyen özellikleri keşfetme, tanımlama ve haritalama konusunda değerli bir yaklaşım sunarlar. Sahte renk bileşimleri konseptini, uygulamalarını ve sınırlamalarını anlamak, disiplinler arası çeşitli uzaktan algılama uygulamalarında etkin kullanımları için önemlidir.

2.1.7. Uzaktan algılamada bant oranlama

Uzaktan algılamada, çok bantlı görüntüler elektromanyetik spektrumun çeşitli bölümleri boyunca verileri yakalar. Görüntüdeki her bant, belirli bir dalga boyu aralığında Dünya'nın yüzey özelliklerinin yansımalarını temsil eder. Bireysel bantları analiz ederken, bant oranları bilgilendirici olabilir, bant oranları, matematiksel bir tekniği, spektral bilgiyi geliştirmek ve ilgilenilen belirli özellikleri çıkarmak için güçlü bir araç sunar.

Bant oranı, bir banttaki bir pikselin yansıma değerini, başka bir banttaki aynı piksele karşılık gelen yansıma değerine bölünmesiyle hesaplanır. Bu işlem esasen yansıma değerlerini normalleştirir, bireysel bantları etkileyebilecek aydınlatma değişikliklerinin ve atmosferik etkilerin etkisini azaltır (Jensen, 2016). Ortaya çıkan oran görüntüsü, seçilen bantlar arasındaki göreceli spektral tepkiyi vurgulayarak genellikle tek bantlarda gizlenebilen ince spektral farklılıkları ortaya çıkarır.


Bant oranları, yansıma değerlerini normalleştirerek, güneş açısı veya atmosferik koşullar gibi faktörlerin neden olduğu aydınlatma değişikliklerinin etkisini azaltır. Belirginleştirilecek yüzeyler arasındaki ince spektral farklılıkları güçlendirerek bitki örtüsünü çıplak topraktan ayırmayı veya farklı kaya türleri arasında ayırım yapmayı kolaylaştırır. Bant oranlamanın ardındaki kavram nispeten basittir ve ortaya çıkan görüntülerin yorumlanması, karmaşık spektral indekslere kıyasla genellikle daha kolaydır.

Ancak bant oranlarını kullanırken bazı hususlar önemlidir. Uygun bantların seçimi, çıkarılan bilgiyi önemli ölçüde etkiler. Hedef özelliklerin spektral özelliklerini anlamak ve bu özelliklere duyarlı bantları seçmek çok önemlidir. Diğer taraftan bant oranlamada paydanın sıfıra bölünmesi, yansımanın olmadığı alanlarda meydana gelebilir ve bu da veri yapaylıklarına neden olabilir. Paydaya küçük bir sabit eklemek gibi teknikler bu sorunu hafifletebilir. Bant oranlama ile belirli spektral bilgileri vurgularken, birden fazla tek bant kullanımına kıyasla verilerin genel boyutluluğunu azaltır.

Bant oranları uzaktan algılama görüntü analizinde değerli bir tekniktir. Bantlar arasındaki göreceli spektral tepkiden yararlanarak, belirli bilgilerin çıkarılması, spektral ayrımcılığın artırılması ve aydınlatma etkilerinin azaltılması için güçlü bir araç sağlarlar. Etkili uzaktan algılama veri analizi için bant oranlarıyla ilgili kavramı, uygulamaları ve hususları anlamak önemlidir.

2.1.8. Uzaktan algılamada spektral açı haritalama (SAM)

Spektral Açı Haritalama (Spectral Angle Mapper - SAM), hiperspektral ve multispektral görüntü verilerini sınıflandırmak için kullanılan uzaktan algılamada yaygın olarak kullanılan denetimli sınıflama yöntemidir. SAM algoritması, görüntüdeki spektral imzalar ile referans kütüphane spektral imzaları (son üyeler) arasındaki benzerliği, bunları yüksek boyutlu bir uzaydaki vektörler olarak ele alarak ve bu vektörler arasındaki açıyı hesaplayarak ölçer (Şekil 2.9). Bu yöntem, jeolojik haritalama, bitki örtüsü analizi ve kentsel alan izleme gibi çeşitli uygulamalar için sağlam bir araç sağlayarak, malzemelerin spektral imzalarına dayalı olarak tanımlanmasında özellikle değerlidir.



Şekil 2.9. Spektral açı haritalama (Muhammad & Saepuloh, 2016)

2.1.9. Uzaktan algılamada temel bileşen analizi (PCA)

Çoğunlukla uydulardan ve havadaki sensörlerden elde edilen uzaktan algılama verileri çok boyutludur. Görüntüdeki her bir piksel, elektromanyetik spektrumun farklı dalga boyları boyunca yansımayı temsil eden birden fazla banda sahiptir. Görüntülerde çok bandın bulunması görsellik ve veri çeşitliliği açısından avantaj sağlarken, verinin analizi aşamasında karmaşıklığı beraberinde getirir. Analiz aşamasında karmaşıklığı

aşmak için Temel Bileşenler Analizi (Principal Component Analysis – PCA) güçlü bir araç olarak ortaya çıkar.

PCA, orijinal verilerdeki en önemli varyansı yakalayan, temel bileşenler (PC'ler) adı verilen yeni bir değişkenler kümesini tanımlayan istatistiksel bir yöntemdir. Bu PC'ler birbirleri ile ilişkili değildir ve belirlenen varyanslara göre sıralanır; ilk PC en fazla varyasyonu yakalar.

PCA, verileri etkili bir şekilde analiz etmek için bant sayısını azaltır. Bu, analizi basitleştirir, hesaplama maliyetini azaltır ve görselleştirmeyi geliştirir. PCA analiz için gereksiz verileri ayıklayarak, en yüksek varyansa sahip bileşenlere odaklanarak verilerde mevcut gürültünün filtrelenmesine yardımcı olur. İlk birkaç PC genellikle verilerdeki temel bilgileri yakalar ve bunları sınıflandırma veya anormallik tespiti gibi analizler için kullanır.

2.2. Makine Öğrenmesi

Makine öğrenmesi (Machine Learning – ML) kavramı için çeşitli tanımlar bulunmaktadır. Tom Mitchell tarafından 1997 yılında yapılan makine öğrenmesi tanımı bu tanımların en popülerlerinden biridir. Mitchell makine öğrenmesini “bir bilgisayar programının, B ile ölçülen G görevlerindeki başarısı D deneyimiyle birlikte artıyorsa, programın G görev sınıflarına ve B başarı ölçüsüne ilişkin D deneyiminden öğrendiği söylenebilir” şeklinde tanımlamıştır (Mitchell, 1997).

Makine öğrenmesi tam olarak programlanmadan verilerden öğrenebilen algoritmalarla ilgilenen yapay zekanın (Artificial Intelligence - AI) bir alt alanıdır (Mitchell, 1997). Bu algoritmalar, verilerdeki kalıpları ve ilişkileri tanımlayarak zaman içinde belirli bir görevdeki performanslarını artırır.

Makine öğrenmesi, bilgisayarların veri analizi ve karar verme süreçlerini otomatikleştiren algoritmalar geliştirmesini içerir. Bu algoritmalar, denetimli, denetimsiz ve pekiştirmeli öğrenme gibi çeşitli tekniklere dayanır. Denetimli öğrenmede, algoritmalar etiketlenmiş verilerden öğrenirken, denetimsiz öğrenmede etiketlenmemiş verilerden kalıplar ve yapılar keşfederler. Pekiştirmeli öğrenme ise, bir ajanı ödül ve ceza mekanizmaları aracılığıyla belirli bir görevi optimize etmeye yönlendirir.

2.2.1. Makine öğrenmesi ve uzaktan algılama

Makine öğrenmesi, uzaktan algılamada genellikle sınıflandırma ve regresyon görevlerinde kullanılır. Özellikle denetimli öğrenme teknikleri, görüntü sınıflandırma işlemlerinde yaygın olarak uygulanır. Destek vektör makineleri (Support Vector Machine - SVM), karar ağaçları (Decision Trees) ve yapay sinir ağları (Artificial Neural Network – ANN) gibi algoritmalar, uzaktan algılama verilerinin analizinde sıklıkla kullanılmaktadır (Schulz et al., 2018).

Makine öğrenmesi algoritmaları, uzaktan algılama verilerinin işlenmesinde çeşitli uygulamalara sahiptir. Örneğin, şehir izleme, yangın tespiti ve sel tahmini gibi uygulamalar, uzaktan algılama ve makine öğrenmesi kombinasyonu ile daha etkili hale gelmektedir (Camps-Valls, 2009). Ayrıca, tarımsal uygulamalarda mahsul verim tahmini ve su stresi tespiti gibi görevlerde makine öğrenmesi teknikleri başarılı sonuçlar vermektedir (Virnodkar et al., 2020).

Makine öğrenmesi, madencilik sektöründe veri analizi ve süreç optimizasyonu için giderek daha fazla kullanılmaktadır. Bu teknikler, büyük veri kümelerinden bilgi çıkarımı ve süreçlerin iyileştirilmesi için kullanılır. Örneğin, çeşitli makine öğrenmesi algoritmaları, mineralojik verilerin analizinde ve maden çıkarma süreçlerinin optimize edilmesinde kullanılmıştır (Jooshaki et al., 2021).

2.2.2. Destek vektör makineleri


Destek Vektör Makineleri (Support Vector Machine - SVM) istatistiksel öğrenme teorisine dayanan, parametrik olmayan bir sınıflandırma algoritmasıdır. İlk olarak Vladimir Vapnik tarafından geliştirilen SVM, iki sınıfa ait pikselleri birbirinden optimum şekilde ayırabilen bir hiperdüzlemin belirlenmesi esasına dayanır (Vapnik, 1995). SVM'nin temel amacı, iki sınıfı en iyi şekilde ayıran ve sınıflandırma hatasını minimize eden bir hiperdüzlemi bulmaktır. Bu algoritmanın önemli bir avantajı, sınıflandırma işlemini gerçekleştirirken sadece destek vektörleri olarak adlandırılan veri noktalarını dikkate almasıdır.

SVM, eğitim veri setindeki sınırlı sayıdaki verilerle yüksek doğrulukta sınıflandırma yapabilme kapasitesine sahiptir. Bu özelliği, SVM'yi diğer sınıflandırma algoritmalarına kıyasla üstün kılmaktadır (Foody et al., 2006; Kavzoğlu & Çölkesen, 2012). Ayrıca, doğrusal olarak ayıramayan verilerin sınıflandırılmasında kernel

fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya taşınmakta ve doğrusal olarak ayrılabilir hale getirilmektedir.


SVM'nin uzaktan algılamada kullanımı, çeşitli çalışmalarda yüksek doğruluk oranları ile rapor edilmiştir. Örneğin, Huang et al. (2002), SVM'nin farklı uzaktan algılama verileri üzerinde üstün performans gösterdiğini ortaya koymuştur. Aynı şekilde, Camps-Valls ve Bruzzone (2009) ile Mountrakis et al. (2011) de SVM'nin yüksek sınıflandırma doğruluğu sağladığını belirtmiştir.

SVM algoritmasının temel çalışma prensibi, iki sınıfa ait pikselleri optimum şekilde ayırabilen bir hiperdüzlemin belirlenmesidir. Şekil 2.10'da gösterildiği gibi, A sınıfı ve B sınıfı olarak adlandırılan iki sınıf arasındaki piksellerin en iyi şekilde ayrılması amaçlanır. Bu ayırım, sınıflar arasındaki uzaklığı maksimum yapan hiperdüzlemi belirlemekle sağlanır.



Şekil 2.10. Optimum hiperdüzlem (Çölkesen,2015)

Mavi çizgiler üzerinde yer alan sarı renkle gösterilen pikseller, destek vektörleri olarak adlandırılır ve sınıflandırma sonucuna en fazla etki eden piksellerdir. Bu piksellerin belirlenmesi, optimum hiperdüzlemin bulunmasında kritik rol oynar. Destek vektörleri arasındaki uzaklığı maksimum yapan hiperdüzlem, sınıflandırma işlemini en iyi şekilde gerçekleştirir (Şekil 2.11).



Şekil 2.11. Destek vektör makineleri ile iki sınıflı veri setinin sınıflandırılması (Çölkesen,2015)

Doğrusal olarak ayrılamayan verilerin sınıflandırılmasında, kernel fonksiyonları kullanılarak veriler daha yüksek boyutlu bir uzaya taşınır. Bu sayede, veriler doğrusal olarak ayrılabilir hale gelir. Kernel fonksiyonları arasında en yaygın kullanılanı, radyal tabanlı fonksiyondur (RTF). RTF, problem çözümündeki etkinliği ve yüksek sınıflandırma doğruluğu nedeniyle tercih edilmektedir (Huang et al., 2002; Melgani & Bruzzone, 2004; Pal & Mather, 2005).


SVM, uzaktan algılama alanında çeşitli uygulamalarda başarılı sonuçlar elde etmiştir. Özellikle, arazi örtüsü sınıflandırması, kentsel alan tespiti ve orman yangını izleme gibi uygulamalarda SVM'nin etkinliği kanıtlanmıştır. (Kavzoğlu ve Çölkesen (2009), SVM'nin arazi örtüsü sınıflandırmasında yüksek doğruluk oranları sağladığını belirtmiştir. Aynı şekilde, Mather & Koch (2011) SVM'nin kentsel alan tespiti ve diğer uzaktan algılama uygulamalarında üstün performans gösterdiğini rapor etmiştir.

SVM uzaktan algılama verilerinin sınıflandırılmasında güçlü ve etkin bir araçtır. Yüksek doğruluk oranları ve sınırlı eğitim verisi ile başarılı sınıflandırma yapabilme kapasitesi, SVM'yi bu alanda tercih edilen bir yöntem haline getirmiştir.

2.2.3. Karar ağaçları

Karar ağaçları (Decision Trees - DT) son yıllarda literatürde yaygın kullanımı olan bir sınıflandırma ve örüntü tanımlama algoritmasıdır (Rogan et al., 2008; Çölkesen, 2009; Goltz et al., 2009; Kavzoğlu ve Çölkesen, 2010; Rodriguez-Galiano ve Chica-Rivas, 2014). Bu algoritma, ağaç yapılarının oluşturulmasında kullanılan karar kurallarının

anlaşılabilir ve sade olması nedeniyle sıklıkla tercih edilmektedir. DT sınıflandırıcısı, sınıflandırma problemlerini tabakalı veya katmanlı bir yapıya dönüştürerek sınıfları birbirinden ayırt etme prensibini benimser (Swain ve Hauska, 1977; Mather ve Koch, 2011). Algoritma, uzaktan algılanmış görüntüler de dahil olmak üzere karmaşık veri setlerinin sınıflandırılmasını aşamalı bir hale getirerek basit karar verme işlemleri gerçekleştirir (Safavian ve Landgrebe, 1991). Bir karar ağacının temel yapısı Şekil 2.12'de görüldüğü üzere düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan oluşur.



Şekil 2.12. Üç sınıfa sahip dört banthı veri seti için oluşturulan karar ağacı yapısı (Çölkesen, 2015)

Bu yapıda, her bir öznelilik bir düğüm tarafından temsil edilir. Dallar ve yapraklar, ağaç yapısının diğer elemanlarıdır. Ağacın en alt kısmı yaprak, en üst kısmı ise kök olarak adlandırılır. Kök ve yapraklar arasındaki kısımlar ise dal olarak ifade edilir (Quinlan, 1993).

Karar ağacının oluşturulmasında temel prensip, eğitim verilerinin öznelilik bilgilerini kullanarak bir dizi soru sormak ve bu sorulara verilen cevaplar doğrultusunda karar kuralları oluşturmaktır. Bu işlem, verilerin sınıflandırılması ve en kısa sürede sonuca ulaşılması hedefiyle gerçekleştirilir. Ağacın ilk düğümü olan kök düğümünden itibaren verilerin sınıflandırılması için sorular sorulmaya başlanır ve dalları olmayan düğümler veya yapraklar bulunana kadar bu süreç devam eder (Pal ve Mather, 2003).

Uzaktan algılama, yeryüzü özelliklerinin uydu veya hava araçları aracılığıyla toplanan veriler kullanılarak analiz edilmesi sürecidir. Uzaktan algılanmış verilerin sınıflandırılması, doğru ve güvenilir çevresel bilgi sağlamak için kritik öneme sahiptir. Bu bağlamda karar ağaçları uzaktan algılama verilerinin sınıflandırılmasında yaygın olarak kullanılan ve etkinliği kanıtlanmış bir yöntemdir.

Karar ağaçları, uzaktan algılama verilerinin sınıflandırılmasında basit ve etkili bir yöntem olarak öne çıkar. Algoritmanın sade ve anlaşılabilir yapısı, kullanıcıların karmaşık veri setlerini anlamalarını ve sınıflandırma işlemlerini kolayca gerçekleştirmelerini sağlar. Karar ağaçları uzaktan algılama verilerinin sınıflandırılmasında yüksek doğruluk oranları sunar ve çeşitli çevresel analizlerde etkin bir şekilde kullanılır (Mather ve Koch, 2011).

Karar ağacı algoritmasının temel çalışma prensibi, bir veri setindeki sınıfları birbirinden ayıran ve sınıflandırmayı en iyi şekilde gerçekleştiren bir ağaç yapısının oluşturulmasıdır. Şekil 2.12'de gösterildiği gibi, karar ağacı yapısında her bir düğüm, veri setindeki bir özneliği temsil eder ve dallar, özneliklerin belirli değerlerine göre verilerin nasıl sınıflandırılacağını gösterir. Yapraklar ise nihai sınıfları temsil eder.

Algoritma, eğitim verilerine dayanarak bir dizi sorular sorar ve bu sorulara verilen cevaplar doğrultusunda ağacı oluşturur. Başlangıçta, kök düğümde sorular sorulmaya başlanır ve bu işlem, dalları olmayan düğümler ya da yapraklar bulunana kadar devam eder. Karar ağacının yapısı, eğitim verilerinin özelliklerine göre şekillenir ve nihai olarak sınıflandırma işlemi gerçekleştirilir.

Karar ağaçları, uzaktan algılama alanında çeşitli uygulamalarda başarılı sonuçlar elde etmiştir. Özellikle, arazi örtüsü sınıflandırması, kentsel alan tespiti ve orman yangını izleme gibi uygulamalarda KA'nın etkinliği kanıtlanmıştır. Kavzoğlu ve Çölkesen (2009), KA'nın arazi örtüsü sınıflandırmasında yüksek doğruluk oranları sağladığını belirtmiştir. Aynı şekilde, Mather ve Koch (2011) de KA'nın kentsel alan tespiti ve diğer uzaktan algılama uygulamalarında üstün performans gösterdiğini rapor etmiştir.

Karar ağaçları, uzaktan algılama verilerinin sınıflandırılmasında güçlü ve etkili bir araçtır. Yüksek doğruluk oranları ve kullanıcı dostu yapısı, KA'yı bu alanda tercih edilen bir yöntem haline getirmiştir.

2.2.4. Sınıflandırma ve regresyon ağaçları

Uzaktan algılama, geniş veri kümeleriyle çalışarak çevresel izleme, doğal kaynak yönetimi ve afet yönetimi gibi çeşitli uygulamalarda kritik bilgiler sağlar. Bu alanda kullanılan yöntemlerden biri olan Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Trees - CART), verileri sınıflandırma ve regresyon modelleri oluşturma amacıyla kullanılan güçlü bir makine öğrenmesi algoritmasıdır.

CART algoritması, veri sınıflandırma ve regresyon analizlerinde kullanılan karar ağaçları modelidir. Bu algoritma, verileri sınıflandırmak veya bir değişkeni tahmin etmek için veri kümesini dallara böler. Her dal, belirli bir kriteri karşılayan veri noktalarını içerir. Bu sayede, veri seti daha küçük ve homojen alt gruplara ayrılır. Sonuç olarak, veri setinin yapısını anlamak ve tahminlerde bulunmak daha kolay hale gelir.

Uzaktan algılamada CART algoritması, özellikle görüntü sınıflandırma ve nesne tespiti gibi görevlerde etkili bir şekilde kullanılmaktadır. Uzaktan algılama görüntüleri genellikle yüksek boyutluluk ve karmaşıklık içerir. Bu nedenle, bu verilerin etkili bir şekilde sınıflandırılması ve analiz edilmesi gerekmektedir. CART bu tür veri kümeleriyle başa çıkmak için uygun bir yöntemdir.

CART algoritması uzaktan algılama verilerinin işlenmesinde çeşitli uygulamalarda kullanılmıştır. Örneğin CART kullanılarak yapılan sınıflandırma çalışmaları, farklı arazi örtüsü türlerini ayırt etmek için etkili olmuştur. Bu, tarım, orman yönetimi ve kentsel planlama gibi alanlarda önemli bilgiler sağlar (Wen et al., 2008).

CART algoritmasının performansını artırmak için çok ölçekli segmentasyon yöntemleri ile birleştirilmiştir. Bu yöntem, uzaktan algılama görüntülerinin homojen bölgeler halinde segmentlere ayrılmasını sağlar. Bu segmentler, daha sonra CART kullanılarak sınıflandırılır. Bu yaklaşım, görüntü gürültüsünü azaltmak ve sınıflandırma doğruluğunu artırmak için etkili bir yöntemdir (Hui, 2012).

CART çeşitli uzaktan algılama uygulamalarında başarıyla kullanılmıştır. Örneğin, tarım alanlarında mahsul türlerinin sınıflandırılması, orman yangınlarının tespiti ve şehir alanlarındaki arazi kullanımı değişikliklerinin izlenmesi gibi uygulamalarda önemli sonuçlar elde edilmiştir. Bu uygulamalar, çevresel izleme ve kaynak yönetimi alanlarında karar vericilere değerli bilgiler sağlamaktadır (Lai-ping, 2007).

CART algoritması, uzaktan algılama verilerinin sınıflandırılması ve analiz edilmesinde etkili bir yöntemdir. Çok ölçekli segmentasyon ve diğer optimizasyon teknikleriyle birleştirilmesi, veri analizi doğruluğunu artırmakta ve çeşitli uygulamalarda önemli avantajlar sağlamaktadır.


2.2.5. Rastgele orman

Toplu öğrenme algoritması olan Rastgele Orman (Random Forest - RF), temel sınıflandırıcı olarak karar ağaçlarını kullanır. RF, bir tür karar ağacı algoritmasıdır ve eğitim aşamasında birçok karar ağacını bir arada kullanarak bir karar ağacı ormanı oluşturur (Breiman, 2001). Şekil 2.13'te gösterilen temel çalışma prensibine göre, RF algoritmasında her bir karar ağacının eğitimi için orijinal eğitim veri setinden rastgele alt kümeler oluşturulur. Bu alt kümelerin 2/3'ü karar ağacını oluşturmak için kullanılırken, geri kalan kısmı ağaç yapısının geçerliliğini test etmek için ayrılır.

Ormandaki her bir karar ağacı, sınıflandırma sonucu olarak bir oy alır ve orman içindeki tüm ağaçlardan en çok oy alan ağaç belirlenerek sınıflandırmaya esas alınır. Sınıf etiketi bilinmeyen herhangi bir örnek tüm ağaç tahminlerinde en fazla oy alan sınıfa atanarak sınıflandırılır.

Rastgele Orman sınıflandırıcısı, karar ağaçlarının oluşumunda dallanma kriterlerinin belirlenmesinde, yani dallanma için özneliliklerin seçiminde Gini İndeksi yöntemini kullanır. Bu sınıflandırıcı için iki temel parametre vardır: her bir düğümde kullanılacak örneklerin sayısı ve oluşturulacak ağaç sayısı. Her bir düğümde en iyi dallanmayı sağlamak için yalnızca seçilen özellikler değerlendirilir. Bu nedenle, Rastgele Orman sınıflandırıcısı kullanıcı tarafından belirlenen n ağaçtan oluşur. Yeni bir veri setinin sınıflandırılmasında, veri seti bu n ağacın her birinden geçirilir. Rastgele Orman sınıflandırıcısı, bu n ağaçtan elde edilen n oy arasında en fazla oya sahip olan sınıfı seçer

ve bu şekilde yeni veri setinin sınıf etiketini belirler (Pal, 2005; Kavzoğlu ve Çölkesen, 2013).



Şekil 2.13. Rastgele orman algoritmasının temel çalışma prensibi (Çölkesen,2015)

2.2.6. K-ortalamlar

K-ortalamlar (K-Means) kümeleme algoritmaları arasında en yaygın olarak kullanılan yöntemlerden biridir. Temel amacı, veriyi k sayıda küme ya da grup içinde sınıflandırmaktır. K-Ortalamlar algoritması şu adımlarla çalışır:

- Başlangıç Küme Merkezlerinin Belirlenmesi: Algoritma, k sayıda küme merkezi seçerek başlar. Bu merkezler genellikle rastgele olarak seçilir.
- Her Noktanın En Yakın Merkeze Atanması: Her veri noktası, en yakın olduğu küme merkezine atanır. Bu, öklidyen uzaklık gibi bir mesafe metriği kullanılarak yapılır.
- Küme Merkezlerinin Güncellenmesi: Her küme için yeni merkez, o kümenin içindeki tüm veri noktalarının ortalaması alınarak güncellenir.
- Tekrar: 2 ve 3. adımlar, küme merkezleri stabil hale gelene kadar (yani merkezler artık değişmeyene kadar) tekrarlanır.

K-Ortalamlar algoritmasının avantajları arasında basitlik ve hızlı çalışma süresi bulunur. Ancak, başlangıç noktalarının seçimine duyarlı olduğu ve yerel minimumlara takılabileceği de unutulmamalıdır.

Uzaktan algılama, yeryüzü hakkında bilgi toplamak için uydu görüntüleri ve hava fotoğraflarının kullanıldığı bir tekniktir. K-Ortalamlar uzaktan algılamada çeşitli amaçlar için kullanılabilir. Uzaktan algılama verileri, farklı arazi tiplerini ve örtü sınıflarını tanımlamak için kullanılabilir. K-Ortalamlar algoritması, uydu görüntülerindeki piksel değerlerini analiz ederek farklı arazi kullanım türlerini ve örtü sınıflarını (orman, su, tarım alanları) belirlemek için kullanılabilir (Baatz & Schäpe, 2000).

Belirli bir bölgedeki değişiklikleri tespit etmek için farklı zamanlarda alınan uydu görüntüleri kullanılabilir. K-Ortalamlar, bu görüntülerdeki farklılıkları belirlemek için kullanılabilir. Örneğin, bir alandaki ormansızlaşma veya kentsel genişleme gibi değişiklikler K-Ortalamlar kullanılarak izlenebilir (Lu et al., 2004).

K-Ortalamlar algoritması, tarım alanlarında verimliliği artırmak için kullanılabilir. Uydulardan elde edilen veriler, farklı bitki sağlık durumlarını ve toprağın verimlilik düzeylerini belirlemek için analiz edilebilir. Bu, çiftçilerin daha bilinçli kararlar almasına yardımcı olur (Bendig et al., 2015).

Sonuç olarak K-Ortalamlar uzaktan algılama verilerini işleyerek arazi kullanım sınıflandırması, değişim tespiti ve hassas tarım gibi çeşitli uygulamalarda önemli katkılar sağlamaktadır.

2.2.7. Öğrenmeli vektör kuantalama (LVQ)

Denetimsiz Öğrenmeli Vektör Kuantalama (Learning Vector Quantization - LVQ) klasik LVQ algoritmasının bir çeşididir ve denetimsiz öğrenme yöntemini kullanır. Klasik LVQ etiketli verilerle çalışırken, denetimsiz LVQ etiketlenmemiş verilerle çalışır ve verilerin doğal gruplarını ortaya çıkarmayı amaçlar. Bu algoritma, genellikle özellik çıkarımı ve veri keşfi için kullanılır.

Denetimsiz LVQ, verilerin alt gruplarını ve desenlerini keşfetmek için güçlü bir yöntemdir. Ancak, başlangıç prototiplerinin seçimi ve hiperparametrelerin ayarlanması performansı önemli ölçüde etkileyebilir.

Uzaktan algılamada denetimsiz LVQ algoritması çeşitli amaçlar için kullanılabilir. Uzaktan algılama verileri, doğal olarak oluşan arazi örtüsü türlerini belirlemek için denetimsiz LVQ algoritması ile analiz edilebilir. Algoritma, benzer spektral özelliklere sahip bölgeleri gruplandırarak, farklı arazi örtüsü tiplerini tanımlamada kullanılabilir (Gómez-Chova et al., 2005).


Belirli bir bölgedeki çevresel değişiklikleri tespit etmek için denetimsiz LVQ kullanılabilir. Farklı zamanlarda alınan uydu görüntüleri, değişikliklerin meydana geldiği bölgeleri belirlemek için analiz edilir. Bu yöntem, özellikle büyük veri setlerinde etkili olabilir (Coppin et al., 2004).





Şekil 3.2. Kırka bor yatakları


Kırka yataklarının stratigrafik yapısı, gölsel sedimanter kayaçlar içindeki kilaşları, marnlar, tüflü epiklastik gibi diğer malzemelerle iç içe geçmiş borakstan oluşmaktadır (Helvacı ve Alonso, 2000). Boraks (tincal), Kırka yatağındaki en baskın borat mineralidir. Ancak, uleksit, kolemanit, tinkalkonit, kernit, Inyoit, inderit, pandemit, hidroboratit, tunitit ve inderborit gibi diğer borat mineralleri küçük miktarlarda meydana gelir (İnan ve ark. 1973). Şekil 3.3, Kırka borat yatağının havadan görünüşünü göstermektedir.




Şekil 3.3. Hidrotermal yapı

Boraks (tincal), uleksit (içe doğru) ve kolemanit (dışarıya doğru) içine alınır ve bunlar, Kırka madeninden ticari miktarlarda elde edilen ana borat tipleridir (Helvacı ve

Alonso, 2000). Kırka yatağı, N-S yönünde yönlendirilmiştir ve hem doğu hem de batı fayları ile sınırlıdır (Helvacı, 2012). Kırka yatağının, hidrotermal akışkan ve ev sahibi ülke kayalarının Paleozoik alüminosilikatlar ve Eosen Kireçtaşı gibi kayalarla etkileşmesinden kaynaklandığı varsayılmıştır (Palmer ve Helvacı, 1997). Kırka Bölgesinin kayaç yapısı ile Şekil 3.4 ve Şekil 3.5’de gösterilmektedir.



Şekil 3.4. Kırka kayaç yapısı-1



Şekil 3.5. Kırka kayaç yapısı-2

3.2. Google Earth Engine (GEE)

Google Earth Engine (GEE), büyük ölçekli çevresel veri analizi ve görselleştirme için tasarlanmış bulut tabanlı bir platformdur. GEE, kullanıcıların uydu görüntüleri ve coğrafi veri setlerini analiz etmelerine ve bunlardan anlamlı bilgiler elde etmelerini sağlamaktadır. Google tarafından geliştirilen platform, dünya çapında bilim insanları, araştırmacılar, devlet kurumları ve çevre koruma örgütleri tarafından yaygın bir şekilde kullanılmaktadır.

GEE, petabaytlarca uydu görüntüsü ve diğer coğrafi veri setlerini barındırmaktadır. Kullanıcılar bu verilere internet üzerinden erişebilir ve bulut tabanlı işlem gücüyle analiz yapabilmektedir. Bu, yerel bilgisayarların sınırlamalarından kurtulmayı ve büyük veri setlerini hızla işlemeyi mümkün kılmaktadır. GEE, çok çeşitli veri kaynaklarına erişim sağlamaktadır. Bu veri kaynaklarına örnekler aşağıda maddeler halinde verilmiştir.

- Landsat Uydu Görüntüleri: 1970'lerden günümüze kadar uzanan yüksek çözünürlüklü görüntüler,

- Sentinel Uydu Görüntüleri: Avrupa Uzay Ajansı tarafından sağlanan yüksek çözünürlüklü görüntüler,

- MODIS (Moderate Resolution Imaging Spectroradiometer): İklim değışikliklerini ve çevresel değışimleri izlemek için kullanılan uydu verileri,

- NOAA (National Oceanic and Atmospheric Administration) verileri: Hava durumu, iklim ve okyanus verileri,

- DEM (Dijital Yükseklik Modelleri): Topoğrafya ve arazi analizi verileri,

- İklim ve Meteoroloji Verileri: Küresel iklim modelleri ve yerel meteorolojik gözlem verileri,

GEE, kapsamlı görüntü işleme, analiz ve görselleştirme araçlarına sahiptir. Platform, Python ve JavaScript gibi popüler programlama dilleriyle entegrasyon sağlamaktadır. Bu sayede kullanıcılar, özel analizler ve otomatik iş akışları oluşturabilmektedir. Analitik araçlar şunları içerir:

- Görüntü İndeksi Hesaplamaları: NDVI, EVI gibi bitki örtüsü indeksleri hesaplamaları,

- Zaman Serisi Analizleri: Zaman içinde veri değışikliklerinin izlenmesi,

- Makine Öğrenimi Uygulamaları: Sınıflandırma ve kümeleme algoritmaları ile arazi kullanımı analizi,

- Coğrafi Analiz: Mekansal veri analizi ve modelleme araçları gibi.

GEE, kullanıcıların analiz sonuçlarını interaktif haritalar üzerinde görselleştirmesine olanak tanımaktadır. Bu haritalar, zaman serisi analizleri yaparak çevresel değışiklikleri izlemeyi kolaylaştırmaktadır. GEE, ayrıca kullanıcıların haritaları özelleştirmelerine ve farklı veri katmanlarını entegre etmelerini sağlamaktadır. GEE kullanılan uzaktan algılama uygulamalarına örnekler aşağıda verilmiştir.

- GEE, arazi kullanımı ve arazi örtüsündeki değışiklikleri izlemek için yaygın olarak kullanılmaktadır. Ormansızlaşma, şehirleşme ve tarım alanlarının değışimi gibi süreçlerin izlenmesi ve analizi mümkündür. Örneğin, Amazon ormanlarındaki ormansızlaşma dinamikleri GEE kullanılarak detaylı bir şekilde analiz edilebilir. Bu analizler, sürdürülebilir arazi yönetimi ve koruma stratejilerinin geliştirilmesine yardımcı olur.

- Tarım ve ormancılık alanında, GEE'nin sağladığı uydu verileri ve analitik araçlar sayesinde çeşitli analizler yapılabilir. Bu analizler şunları içerir. Örneğin mahsul sağlığı izleme, sulama ihtiyaçlarının belirlenmesi, verimlilik analizleri, orman yangın tespiti ve yangın sonrası zararların değerlendirilmesi gibi.

- GEE, doğal afetlerin izlenmesi ve analizi için kritik bir araçtır. Sel, deprem, volkanik patlamalar gibi doğal afetlerin öncesi ve sonrası analizleri yapılabilir.

- Su kaynaklarının yönetimi, GEE'nin kritik kullanım alanlarından biridir. Su kütlelerinin izlenmesi ve analiz edilmesi için kullanılmaktadır.

- GEE, madencilik faaliyetlerinin izlenmesi ve çevresel etkilerinin değerlendirilmesi için kullanılmaktadır. Örnek kullanım örnekleri aşağıda maddeler halinde verilmiştir.

Uydu görüntüleri ve spektral analizler kullanılarak potansiyel maden yataklarının belirlenmesi.

Madencilik faaliyetlerinin çevresel etkilerinin izlenmesi ve değerlendirilmesi. Örneğin, maden ocaklarının genişlemesi, bitki örtüsü kaybı ve su kirliliği gibi etkilerin analiz edilmesi.

Madencilik faaliyetlerinin neden olduğu arazi değişikliklerinin izlenmesinde kullanılmaktadır. Bu, özellikle açık ocak madenciliği gibi büyük ölçekli faaliyetlerin etkilerini değerlendirmede önemlidir.

Kullanımdan kaldırılan maden sahalarının restorasyon ve reklamasyon süreçlerinin izlenmesi ve planlanmasında kullanılmaktadır.

Google Earth Engine, uzaktan algılama ve coğrafi bilgi sistemleri (GIS) alanında güçlü bir araçtır. Bu tez kapsamında GEE, zengin veri kaynaklarına ulaşım kolaylığı sağlaması, büyük verileri işleme yeteneği ve uydu görüntüleri için uygulanan yöntemler için analiz araçlarına sahip olmasından dolayı kullanılmıştır. Ayrıca tez çalışmasında kullanılan uydu görüntüleri için yüzey yansıma değerleri hesaplanmış ve atmosferik düzenlemelerin yapılmış veri setlerine GEE erişiliyor olması, uzaktan algılama iyileştirme ve ön işlem adımlarının yapılmış olması da karşılaşılabilecek operatör/düzenleme hatalarının önüne geçmiştir.

3.3. Kullanılan Uydu ve Uydu Görüntüleri

Çalışma kapsamında Landsat 8 ve Sentinel 2 uydu görüntüleri bor minerali aramak için veri kaynağı olarak kullanılmıştır.

3.3.1. Landsat programı ve uyduları

Landsat programı, Amerika Birleşik Devletleri'nin NASA (Ulusal Havacılık ve Uzay Dairesi) ve USGS (Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu) iş birliğiyle yürütülen, dünya yüzeyinin uzun vadeli izlenmesini sağlayan en uzun soluklu uydu tabanlı uzaktan algılama programıdır. 1972 yılında başlatılan bu program, yeryüzündeki doğal ve insan kaynaklı değişiklikleri izlemek için kritik veriler sağlamaktadır. Landsat uyduları, yüksek çözünürlüklü görüntüler sunarak arazi kullanımı, tarım, ormancılık, su kaynakları yönetimi ve çevresel izleme gibi pek çok alanda geniş uygulama alanları bulmaktadır.

Landsat programı, başlangıçta Earth Resources Technology Satellite (ERTS) olarak adlandırılan Landsat 1'in 1972'de fırlatılmasıyla başladı. İlk nesil Landsat uyduları, Multispectral Scanner System (MSS) adı verilen sensörlerle donatılmıştı. MSS, dört spektral bantta veri topluyordu: yeşil, kırmızı, yakın kızılötesi ve orta kızılötesi. Bu uydular, dünya yüzeyinin geniş alanlarının haritalanmasına olanak sağladı.

1980'lerin başında, Landsat 4 ve 5 uyduları, daha gelişmiş bir sensör olan Thematic Mapper (TM) ile donatıldı. TM, yedi spektral bantta veri topluyor ve daha yüksek çözünürlüklü görüntüler sağlıyordu. Ayrıca, TM sensörü ile birlikte MSS sensörü de kullanılmıştır.

Landsat 6, 1993 yılında fırlatıldı ancak yörüngeye ulaşamadı. Bunun ardından, 1999 yılında fırlatılan Landsat 7, Enhanced Thematic Mapper Plus (ETM+) sensörü ile donatıldı. ETM+, TM sensörüne ek olarak bir pankromatik bant ve termal kızılötesi bant içeriyordu.

Landsat 8, 2013 yılında fırlatıldı ve Operational Land Imager (OLI) ve Thermal Infrared Sensor (TIRS) sensörleri ile donatıldı. Bu sensörler, daha yüksek doğruluk ve güvenilirlikle veri toplamaktadır. Landsat8 halen aktif şekilde görevine devam etmektedir. Landsat 9 ise 2021'de fırlatıldı ve benzer sensörlerle donatılmıştır, böylece Landsat programının sürekliliği sağlanmıştır. Tez kapsamında kullanılan uydu

görüntüleri Landsat 8 uydularından elde edilmiş olup, Landsat 8 uydusunun sağladığı bantlar ve özellikleri Tablo 3.1’de verilmiştir.

Tablo 3.1. Landsat 8 bantları (*http-2*)

Landsat 8 Operasyonel Arazi Görüntüleyicisi (OLI) ve Termal Kızılötesi Sensörü (TIRS) Başlatıldı. 11 Şubat 2013	Bantlar	Daga Boyu (mikrometre)	Çözünürlük (metre)
	Bant 1 - Kıyı Aerosolu	0.43-0.45	30
	Bant 2 - Mavi	0.45-0.51	30
	Bant 3 - Yeşil	0.53-0.59	30
	Bant 4 - Kırmızı	0.64-0.67	30
	Bant 5 - Yakın Kızılötesi (NIR)	0.85-0.88	30
	Bant 6 - SWIR 1	1.57-1.65	30
	Bant 7 - SWIR 2	2.11-2.29	30
	Bant 8 - Pankromatik	0.50-0.68	15
	Bant 9 - Cirrus	1.36-1.38	30
	Bant 10 - Termal Kızılötesi (TIRS) 1	10.60-11.19	100
	Bant 11 - Termal Kızılötesi (TIRS) 2	11.50-12.51	100

3.3.2. Sentinel uyduları ve Copernicus programı


Sentinel uyduları, Avrupa Uzay Ajansı (ESA) tarafından yürütülen ve Avrupa Birliği'nin finanse ettiği Copernicus programı kapsamında geliştirilen bir dizi uydu sistemidir. Bu program, Sentinel-1, Sentinel-2, Sentinel-3, Sentinel-4, Sentinel-5, Sentinel-5P ve Sentinel-6 aktif uydu serilerinden oluşmaktadır. Copernicus programı kapsamında çevresel izleme, güvenlik hizmetleri, dünya yüzeyinin, okyanusların ve atmosferin sürekli izlenmesini sağlayan çeşitli veriler, uygulamalar ve hizmetler sunulmaktadır.

Sentinel-2, optik görüntüleme uyduları serisidir ve multispektral görüntüleme özelliğine sahiptir. Yüksek çözünürlüklü optik kameralarla donatılmış bu uydular, 13 spektral bantta veri sağlar. Bu bantlar, görünür spektrumdan kısa dalga kızılötesi (SWIR) spektruma kadar uzanır. Sentinel-2A uydusu 2015 yılında Sentinel-2B ise 2017 yılında fırlatılmıştır.

Çalışmada Sentinel-2 uydu verileri kullanış olup Sentinel-2'nin sağladığı spektral bantlar ve dalga boyları ve özellikleri Tablo 3.2’de verilmiştir. Landsat8 ve Sentinel-2 uydularının bantları dalga boyu aralıkları cinsinden karşılaştırılması Şekil 3.5’de verilmiştir. Sentinel-2 uydularının sağladığı spektral bantlar ve dalga boyları:

Tablo 3.2. *Sentinel 2 bantları (http-3)*

Bant No	Bant Adı	Dalga Boyu (nm)	Çözünürlük (m)
1	Kıyı/Aerosol	443	60
2	Mavi	490	10
3	Yeşil	560	10
4	Kırmızı	665	10
5	Bitki Örtüsü Kırmızı Kenar	705	20
6	Bitki Örtüsü Kırmızı Kenar	740	20
7	Bitki Örtüsü Kırmızı Kenar	783	20
8	NIR (Yakın Kızılötesi)	842	10
8a	Dar NIR	865	20
9	Su Buharı	945	60
10	SWIR-Cirrus	1375	60
11	SWIR	1610	20
12	SWIR	2190	20



Şekil 3.6. *Lantsat8 OLI ve Sentinel-2 MSI uydu bantlarının dalga boyu cinsinden karşılaştırılması (Sigurdsson ve ark, 2022)*

3.4. USGS Spektral Kütüphanesi

Uzaktan algılama, çeşitli doğal ve insan yapımı malzemelerin spektral özelliklerini analiz etmek için güçlü bir araçtır. Bu bağlamda, spektral kütüphaneler, belirli malzemelerin spektral imzalarını depolayarak araştırmacılara büyük bir kaynak sunar. USGS (United States Geological Survey) Spektral Kütüphanesi, çeşitli doğal ve sentetik malzemelerin spektral özelliklerinin kataloglandığı geniş bir veritabanıdır. Bu kütüphane, mineralojik, jeolojik, çevresel ve uzaktan algılama araştırmaları için temel bir kaynak olarak hizmet eder. Spektral kütüphane, malzemelerin elektromanyetik spektrumun farklı bölgelerinde (ultraviyole, görünür, yakın kızılötesi, kısa dalga kızılötesi, termal kızılötesi) yansıma ve emilim özelliklerini içerir. Bu veriler, özellikle uydu ve hava araçlarından elde edilen uzaktan algılama verilerinin analizinde kullanılır.

USGS Spektral Kütüphanesi, binlerce mineral, kaya, toprak, bitki ve insan yapımı malzemenin spektral verilerini içerir. Her bir spektral imza, malzemenin belirli dalga

boylarındaki yansıma veya emilim karakteristiklerini gösterir. Bu imzalar, laboratuvar ortamında yüksek doğrulukla ölçülerek kataloglanmıştır.

USGS Spektral Kütüphanesi, spektral analiz alanında bir referans noktası olarak büyük bir öneme sahiptir. Bu kütüphane, hem bilimsel araştırmalarda hem de endüstriyel uygulamalarda güvenilir ve doğrulanmış spektral veriler sağlar. Ayrıca, geniş malzeme yelpazesi ve sürekli güncellenen veri tabanı, kullanıcıların ihtiyaçlarına göre özelleştirilmiş analizler yapmasına olanak tanır.

En güncel USGS spektral kütüphanesi 7. Versiyonudur. Bu kütüphanedeki spektrumları ölçmek için dört farklı spektrometre tipi kullanılmıştır:

- 0,2 ila 3 μm spektral aralığını kapsayan Beckman™ 5270
- Standart, yüksek çözünürlüklü (hi-res) ve yüksek çözünürlüklü Yeni Nesil (hi-resNG) ASD saha taşınabilir spektrometreleri modelleri 0,35 ila 2,5 μm aralığını kapsar
- Yaklaşık 1,12 ila 216 μm aralığını kapsayan Nicolet™ Fourier Transform Infra-Red (FTIR) interferometre spektrometreleri
- NASA Havadan Görünür/Kızılötesi Görüntüleme Spektrometresi AVIRIS, 0,37 ila 2,5 μm aralığını kapsar

Orijinal ölçümleri sağlamanın yanı sıra, spektrumlar farklı spektrometre ve multispektral sensör özelliklerine göre dönüştürülmüş ve yeniden örneklenmiştir.

Bu tez kapsamında USGS 7 Kütüphanesinden aşağıdaki dosya türleri kullanılmıştır.

- splib07a - Beckman, ASD, Nicolet ve AVIRIS spektrometrelerinde ölçülen spektrumları içeren dosyası
- s07LSAT8 - Landsat-8 Operational Land Imager'ın (OLI) yanıt fonksiyonlarına göre yeniden örneklenen dosya
- s07SNTL2 - Sentinel-2 Multispektral Enstrümanının (MSI) yanıt fonksiyonlarına yeniden örneklenen dosyası

Bu tez kapsamında USGS spektral kütüphanesinden başta bor minerallerinin spektral imzaları (farklı spektrometre / uyduları kapsayacak şekilde) olmak üzere uzaktan algılama verilerinin yorumlanması için kullanılmıştır.

3.4.1. USGS kütüphanesi bor minerali ve spektral özellikleri


Bor mineralleri, içerdikleri bor elementi ile tanımlanan ve sanayide geniş kullanım alanına sahip mineral grubudur. Bu mineraller, cam, seramik, gübre, deterjan ve çeşitli kimyasalların üretiminde kullanılır.

Bor, doğada çeşitli mineraller halinde bulunur ve genellikle borat mineralleri olarak adlandırılır. Bor mineralleri, borik asit ve bor oksitlerin çeşitli metallerle oluşturduğu bileşiklerdir. Bor mineralleri arasında boraks(Sodyum borat), kolemanit (Kalsiyum borat), uleksit (Sodyum kalsiyum borat) ve kernit gibi mineraller yer almaktadır. Bu mineraller, genellikle evaporit yataklarında bulunur ve suyun buharlaşmasıyla çökelirler.

Bor mineralleri, belirli dalga boylarında karakteristik spektral özellikler gösterir. Bu özellikler, minerallerin uzaktan algılama verileri kullanılarak tanımlanmasını sağlar. USGS Spektral Kütüphanesi'nde bor minerallerinin spektral imzaları detaylı olarak yer almaktadır. Bu tez çalışmasında USGS kütüphanesinde yer alan, Tinkal(Tincalconite), Kolemanit (Colemanite) ve Uleksit (Ulexit) spektral imzaları kullanılmıştır. USGS kütüphanesinde iki farklı numuneye (GDS138 ve HS441) göre Uleksit imzası olduğu ikiside kullanılmıştır.


Beckman Spektrometresine (splib07a) göre laborotuar ortamında alınan spektral ölçümler ile;

- **Tinkal** (sodyum borat): 1.4 μm ve 1.9 μm dalga boylarında belirgin emilim bantları gösterir. Ayrıca, 2.1 μm ve 2.3 μm 'de daha zayıf emilim özellikleri görülür (Şekil 3.6a).
- **Kolemanit** (kalsiyum borat): 1.42 μm ve 1.9 μm 'de güçlü emilim bantları vardır. Ayrıca, 2.2 μm civarında zayıf emilim özellikleri gösterir (Şekil 3.6b).
- **Uleksit** (sodyum kalsiyum borat): 1.45 μm ve 1.9 μm 'de belirgin emilim bantları ile tanımlanır. 2.1 μm ve 2.4 μm civarında daha zayıf emilim bantları bulunur. İki farklı numune GDS138 için Şekil 3.6c, HS441 için Şekil 3.6d'de spektral imzalar gösterilmiştir.




Şekil 3.7. Beckman spektrometresine (splib07a) göre laboratuvar ortamında elde edilen spektral

Landsat8 uydusu OLI sensörü (s7LSAT8) yanıt fonksiyonlarına göre yeniden örneklenmiş spektral imzalar aşağıda verilmiştir. Bu örneklemede Landsat8 uydusunun VNIR ve SWIR banlarının tamamı (7 bandı) kullanılmıştır (Şekil 3.7).



Şekil 3.7. Landsat8 OLI (s7LSAT8) yanıt fonksiyonlarına göre yeniden örneklenmiş spektral değerler

Sentinel-2 uydusu MSI sensörü (s7SNTL2) yanıt fonksiyonlarına göre yeniden örneklenmiş spektral imzalar aşağıda verilmiştir. Bu örneklemede Sentinel-2 uydusunun VNIR ve SWIR banlarının tamamı (12 bandı) kullanılmıştır (Şekil 3.8).



Şekil 3.8. Sentinel-2 MSI (s7SNTL2) yanıt fonksiyonlarına göre yeniden örneklenmiş spektral değerler

3.5. Kullanılan Uzaktan Algılama Yöntemleri

Türkiye'deki Eskişehir Seyitgazi Kırka bölgesinde bor cevherleri, özellikle kolemanit, üleksit ve tinkal gibi bor mineralleri açısından zengindir. Bu bölgede bor mineralleri genellikle evaporit ortamlarında oluşur ve belirli yan kayaç türleri ile ilişkilidir. Kırka bölgesinde aranması gereken yan kayaçlar ve alterasyon türleri:

- **Volkanik Kayaçlar**

Genellikle bor minerallerinin oluşumuna katkıda bulunan volkanik tüfler, bor minerallerinin bulunduğu yatakların önemli bir göstergesidir. Aynı şekilde, silis bakımından zengin volkanik kayaçlar olan riyalitlerde hidrotermal alterasyonun bir sonucu olarak bor minerallerini içerebilir.

- **Evaporit Kayaçlar**

Bor mineralleri, evaporit ortamlarında sıklıkla kireçtaşı ile birlikte bulunur. Kireçtaşı, bor mineralleri için bir ana kayaç olarak görülebilir. Ayrıca bor yataklarının yakınında Jips (Alçıtaşı) yaygın olarak bulunabilir ve bor minerallerinin varlığına işaret edebilir.

- **Killi Kayaçlar**

Alterasyonla kil mineralleri (örneğin montmorillonit) oluşturan kayaçlar, bor mineralleri ile ilişkilendirilebilir. Kil mineralleri, bor minerallerinin oluşumuna eşlik eden alterasyon ürünleridir. Kil ve kireçtaşının bir karışımı olan marllar, bor yataklarının bulunduğu bölgelerde yaygın olarak bulunabilir.

- **Alterasyon Türleri**

Propilitik alterasyon, klorit, epidot ve kalsit gibi minerallerin oluşumunu içerir ve bor yataklarının bulunduğu bölgelerde yaygın olabilir. Aynı şekilde Kil minerallerinin oluşumunu içeren argillitik alterasyon da, bor minerallerinin bulunduğu yerlerde görülebilir. Bunun dışında kuvars zenginleşmesi, bor yataklarının yakınında bulunabilir ve uzaktan algılama ile tespit edilebilir.


Uydu görüntülerini ve uzaktan algılama yöntemlerini kullanarak, yukarıdaki belirtilen yan kayaçları ve alterasyon türlerini tespit edebilmektedir. Bu tez kapsamında aşağıda maddeler halinde belirtilen uzaktan algılama analiz yöntemleri kullanılarak bor minerali potansiyel haritaları oluşturulmuştur.

- Sahte Renk Bileşimleri (False Color Combinations)
- Bant Oranlama (Band Ratioing)
- Spektral Açık Haritalama (Spektral Angle Mapper)
- Temel Bileşenler Analizi (Principal Component Analysis)

3.5.1. Sahte renk bileşimleri


Uydu görüntüleri yardımıyla bor minerallerini belirgin kılabilmek için kullanılabilecek uygun bir sahte renk bileşimleri, genellikle bor minerallerinin spektral özelliklerine ve uydunun sunduğu bantların özelliklerine dayanmaktadır. Şekil 3.9'da tez

kapsamında kullanılan Landsat 8 uydu görüntüsünün bantlarının histogramı gösterilmiştir. Histogramlar incelendiğinde 5. (NIR) ve 6. (SWIR-1) bantlarında anomali olduğu gözlemlenmiştir.



Şekil 3.9. Landsat 8 bantlarının yüzey yansıtma değerlerine göre bant histogramları

Ayrıca Şekil 3.10'da tez kapsamında kullanılan Sentinel 2 uydu görüntüsünün bantlarının histogramı gösterilmiştir. Histogramlar incelendiğinde 4. (Red), 5. (VNIR) ve 11. ve 12. (SWIR-1) bantlarında anomali olduğu gözlemlenmiştir.



Şekil 3.10. Sentinel 2 bantlarının yüzey yansıtma değerlerine göre bant histogramları

Bor minerallerinin tespiti için kısa dalga kızılötesi (Short Wave InfraRed - SWIR) bantları ve yakın kızılötesi (Near InfraRed - NIR) bantları kullanılmaktadır. SWIR ve NIR bantları kullanarak, alterasyona uğramış kayalar ve bor minerallerinin varlığı belirginleşmektedir. Bor minerallerinin yoğun olduğu alanlar, genellikle SWIR ve NIR bantlarında yüksek yansıtma göstermekte, bu alanlar sahte renk bileşim görüntülerde parlak tonlarda veya belirgin renk kontrastlarıyla görüntülenebilmektedir.


Landsat 8 uydu görüntüsü, çalışma alanı değerlendirmek için yapılan sahte renk bileşimleri, bor minerallerin özellikleri ve histogram grafikleri doğrultusunda iki farklı sahte renk birleşimi uygulanmıştır. Tez kapsamında; bor mineralleri tespiti için Landsat8 uydusu üzerinden kullanılan sahte renk bileşimi:

R: Bant 6

G: Bant 5

B: Bant 4

Bu bant bileşimi (6-5-4), minerallerin ve alterasyon zonlarının belirginleştirilmesinde etkilidir. SWIR1 ve NIR bantları, minerallerin yansıtma özelliklerini ortaya çıkarırken kırmızı bant, toprağın ve bitki örtüsünün ayrımını yapmaktadır. Görüntü en yüksek değerlere göre (min 0,4- max: 0,6) filtrelendiğinde, Kırka Bor işletmesi ve açık maden ocağı alanı turkuaz- beyaz renklerle görünür şekilde ayrışmaktadır. (Şekil 3.11)



Şekil 3.11. Landsat 8 sahte renk bileşimi (Bant 6-5-4)

Ayrıca kullanılan ikinci sahte renk bileşimi:


R: Bant 7

G: Bant 6

B: Bant 5

Bu bileşimi (7-6-5), SWIR bantlarının kullanımı ile alterasyon zonlarını daha net bir şekilde belirginleştirmektedir. Bu bileşimde alterasyon zonlarının belirginleştiği

görülmüştür. Görüntü en yüksek değerlere göre (min 0,4- max: 0,6) filtrelendiğinde, Kırka Bor işletmesi ve açık maden ocağı alanı mavi- beyaz renklerle görünür şekilde ayrıışmaktadır. (Şekil 3.12)



Şekil 3.12. Landsat 8 sahte renk birleşimi (Bant 7-6-5)

3.5.1.2. Sentinel 2 görüntüleri ile sahte renk bileşimleri


Tez kapsamında; bor mineralleri tespiti için Sentinel 2 uydusu üzerinden kullanılan sahte renk bileşimleri:

R: Bant 12

G: Bant 8A

B: Bant 4

Bu bileşim, SWIR ve NIR bantlarını kullanarak minerallerin belirgin hale gelmesini sağlamaktadır. Şekil 3.13’de görüleceği üzere bu gösterimde minerallerin ve alterasyon zonlarının belirginleştiği görülmektedir. Görüntü en yüksek değerlere göre (min 0,5- max: 0,6) filtrelendiğinde, Kırka Bor işletmesi ve açık maden ocağı alanı turkuaz- beyaz renklerle görünür şekilde ayrıışmaktadır.



Şekil 3.13. *Sentinel 2 sahte renk bileşimi (Bant 12-8A-4)*


Ayrıca kullanılan ikinci sahte renk bileşimi:

R: Bant 11

G: Bant 12

B: Bant 8A

Bu bileşim, bor minerallerin ayrıştırılmasını daha net bir şekilde sağlamaktadır (Şekil 3.14) Bu birleşimde alterasyon zonlarının belirginleştiği görülmüştür. Görüntü en yüksek değerlere göre (min 0,5- max: 0,7) filtrelendiğinde, Kırka Bor işletmesi ve açık maden ocağı alanı mavi- açık pembe renklerle görünür şekilde ayrılmaktadır.



Şekil 3.14. *Sentinel 2 sahte renk birleşimi (Bant 11-12-8A)*


Kullanılan üçüncü sahte renk bileşimi:

R: Bant 11

G: Bant 8

B: Bant 2

Bu bileşim, bu gösterimde minerallerin ve alterasyon zonlarının belirginleştiği görülmektedir. (Şekil 3.15) Bu birleşimde alterasyon zonlarının belirginleştiği görülmüştür. Görüntü en yüksek değerlere göre (min 0,5- max: 0,7) filtrelendiğinde, Kırka Bor işletmesi ve açık maden ocağı alanı yeşil- sarı renklerle görünür şekilde ayrıışmaktadır.



Şekil 3.15. Sentinel 2 sahte renk birleşimi (Bant 11-8-2)

3.5.2. Bant oranlama

Bant oranlaması minerallerin haritalandırılmasında en yaygın kullanılan yöntemlerden biridir. Minerallerin farklı dalga boylarında göstermiş olduğu spektral yansıma değeri göz önünde bulundurularak çeşitli oranlamalar yapılmaktadır. (Nilüfer, 2005; Kargı ve Nilüfer, 2006).

Bant oranlama, bir görüntüdeki iki veya daha fazla spektral bant arasındaki oranların hesaplanması ile gerçekleştirilmektedir. Bu oranlar, belirli özelliklerin veya maddelerin daha iyi tanımlanmasını ve ayrılmasını sağlamaktadır.

3.5.2.1. Landsat8 görüntüleri ile bant oranlama çalışmaları

Bor mineralleri, Landsat8 uydu verilerinde B5 (Yeşil) bantta yüksek yansıtıcılığa, B7 (Kırmızı Kenarı) bandında düşük yansıtıcılığa sahiptir. Ayrıca, B4 (Mavi) bant, bor


minerallerinin ayrımında yardımcı olabilecek ek bilgiler sağlamaktadır. Tez çalışmasında aşağıdaki oranlar Landsat8 uydu görüntüleri kullanılarak uygulandı.

(Band5/Band7): Bu oran, bor minerallerinin yüksek yeşillik ve düşük kırmızı kenarı yansıtıcılığına dayanan ayrımını sağladı.

(Band4/Band7): Bu oran, bor minerallerinin mavi ve kırmızı kenarı yansıtıcılığına dayanan ayrımını sağladı.

(Band5/Band4): Bu oran, bor minerallerinin yüksek yeşillik ve düşük mavi yansıtıcılığına dayanan ayrımını sağladı.


Landsat 8 uydu görüntüsünün tamsayı yansıma değerleri ölçekleme çarpanı ve offset değerlerini kullanarak yansıma değerlerine dönüştürülmüştür. Bor minerallerini ayırt etmek için Landsat 8 uydu görüntüsünün beşinci ve yedinci bantları oranlanarak yüksek oranları (min:4) gösterecek şekilde düzenlenmiş ve Şekil 3.16'da gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını göstermekte ancak açık maden ocağıyla ilgili kısıtlı bilgi vermektedir.



Şekil 3.16. *Bant5/Bant7 Bant oranı gösterimi*

Landsat 8 uydu görüntüsünün dördüncü ve yedinci bantları oranlanarak yüksek değerlere göre (min:1,5 max:2,5) düzenlenmiş ve Şekil 3.17'de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi net bir şekilde görülmekte ve kırka açık maden alanı içinde bazı alanlar

belirginleşmiştir.




Şekil 3.17. *Bant4/Bant7 Bant oranı gösterimi*

Landsat 8 uydu görüntüsünün beşinci ve dördüncü bantları oranlanarak düşük değerlere göre (min:1,3) düzenlenmiş ve Şekil 3.18’de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi net bir şekilde görülmekte ve kırka açık maden alanı belirginleşmiştir.



Şekil 3.18. *Bant5/Bant4 Bant oranı gösterimi*

Landsat 8 uydu görüntüsünün Bant 5/Bant 7 (Kırmızı), Bant 5/Bant 4 (Yeşil), Bant 4/Bant 7 (Mavi) oranları sahte renk birleşimi oluşturulup, değerlere göre (min:1, max:1,3) düzenlenmiş ve Şekil 3.19’da gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi mavi renk ile net bir şekilde görülmekte ve kırka açık maden alanı pembe renk ile belirginleşmiştir.



Şekil 3.19. *Bant oranlarının sahte renk birleşimi gösterimi*

3.5.2.2 Sentinel-2 görüntüleri ile bant oranlama çalışmaları

Bor mineralleri, Sentinel-2 uydu görüntülerinde B5 (Yeşil) bantta yüksek yansıtıcılığa, B7 (Kırmızı Kenarı) ve B11 (Kırmızı Kenarı) bandında yüksek yansıtıcılığa sahiptir. Ayrıca, B12 (NIR) bant, bor minerallerinin ayrımında yardımcı olabilecek ek bilgiler sağlamaktadır. Tez çalışmasında aşağıdaki oranlar Sentine 2 uydu görüntüleri kullanılarak uygulandı.

(Band11/Band5): Bu oran, bor minerallerinin mavi bantta düşük yansıtıcılığına ve kırmızı kenarı bandında yüksek yansıtıcılığına dayanan ayrımını sağlar.

(Band7/Band5): Bu oran, bor minerallerinin mavi bantta düşük yansıtıcılığına ve kırmızı kenarı bandında yüksek yansıtıcılığına dayanan ayrımını sağlar.

(Band12/Band5): Bu oran, bor minerallerinin mavi bantta düşük yansıtıcılığına ve NIR bandında yüksek yansıtıcılığına dayanan ayrımını sağlar.

Sentinel 2 uydu görüntüsünün tamsayı yansıma değerleri ölçekleme çarpanı kullanılarak yansıma değerlerine dönüştürülmüştür. Bor minerallerini ayırt etmek için Sentinel 2 uydu görüntüsünün onbirinci ve beşinci bantları oranlanarak düşük oranları (max:0,8) gösterecek şekilde düzenlenmiş ve Şekil 3.20’de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve su alanları siyah renk ile gösterilmekte ancak açık maden ocağıyla ilgili kısıtlı bilgi vermektedir.



Şekil 3.20. *Bant11/Bant5 Bant oranı gösterimi*

Sentinel 2 uydu görüntüsünün yedinci ve beşinci bantları oranlanarak düşük değerlere göre (max:1,2) düzenlenmiş ve Şekil 3.21’de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi net bir şekilde görülmekte ve kırka açık maden alanı belirginleşmiştir.




Şekil 3.21. *Bant7/Bant5 Bant oranı gösterimi*

Sentinel 2 uydu görüntüsünün onikinci ve beşinci bantları oranlanarak düşük değerlere göre (max:0,2) düzenlenmiş ve Şekil 3.22’de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi görülmekte ancak açık maden ocağıyla ilgili kısıtlı bilgi vermektedir.



Şekil 3.22. *Bant12/Bant5 Bant oranı gösterimi*

Sentinel 2 uydu görüntüsünün Bant 7/Bant 5, Bant 11/Bant 5, Bant 12/Bant 5 oranları sahte renk birleşimi oluşturulup, değerlere göre (min:1, max:1,5) düzenlenmiş ve Şekil 3.23’de gösterilmiştir. Bu gösterimde Kırka açık maden işletmesinin havuz alanını ve alanda bulunan su alanlarının gösterimi mavi renk ile net bir şekilde görülmekte ve kırka açık maden alanı pembe renk ile belirginleşmiştir.



Şekil 3.23. *Bant oranlarının sahte renk birleşimi gösterimi*

3.5.3. Spektral açı haritalama


Spektral Angle Mapper (SAM), uzaktan algılama verilerinde mineral tespiti için kullanılan bir yöntemdir. Bu yöntem, bir pikselin spektral imzası ile referans spektral imza arasındaki açıyı ölçerek mineral tespiti yapar.

Tez çalışması kapsamında spektral açı haritalaması kullanılarak, Landsat 8 ve Sentinel 2 uydu görüntüleri için ayrı ayrı uygulandı. Her bir mineralinin USGS Spektral kütüphanesinde Landsat 8 ve Sentinel 2 için örneklenmiş spektral imzaları kullanılarak


bor mineralleri için referans spektrumlar oluşturuldu. Uydu görüntülerinin VNIR ve SWIR bantları bir diziye dönüştürülerek, görüntü pikselleri ile referans spektrumlar arasındaki spektral açının hesaplanması yapıldı. Bu hesaplamadan yararlanılarak; düşük spektral açığa sahip (yüksek benzerliğe sahip) pikseller tanımlandı. Potansiyel bor minerallerini gösteren maske uygulanmış görüntü ve SAM analiz haritası oluşturuldu.

3.5.3.1. Landsat8 görüntüleri ile SAM

SAM uygulamak için Tinkal, Kolemanit ve Uleksit için spektral imzaları ve Landsat 8 uydu görüntüsünde hangi bant ve dalga boylarına karşılık geldiği Şekil 3.24 ve 3.25'te gösterilmiştir.



Şekil 3.24. Landsat 8 bantlarına göre bor minerallerinin yansımaya değerleri gösterimi



Şekil 3.25. Landsat 8 bantlarının dalgaboylarına göre bor minerallerinin yansımaya değerleri gösterimi

Şekil 3.26’da görüldüğü üzere, Landsat 8 uydu görüntüsü üzerinden Tinkal için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça siyah renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.26. Landsat 8 tinkal spektral aç haritalaması

Şekil 3.27’de görüldüğü üzere, Landsat 8 uydu görüntüsü üzerinden Kolemanit için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça kırmızı renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.27. Landsat 8 kolemanit spektral aç haritalaması

Şekil 3.27’de görüldüğü üzere, Landsat 8 uydu görüntüsü üzerinden üleksit gd138 için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça yeşil renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.28. *Landsat 8 uleksi gd138 spektral aç haritalaması*

Şekil 3.28’de görüldüğü üzere, Landsat 8 uydu görüntüsü üzerinden üleksi hd441 için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça mavi renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.




Şekil 3.29. *Landsat 8 uleksi hd441 spektral aç haritalaması*


Bor mineralleri için SAM uyguladığımız zaman su havzalarıyla yansıma değerleri karışabilmekte Kırka Bor açık maden sahası ile birlikte su yüzeyleri de görünmektedir.

3.5.3.2. Sentinel-2 görüntüleri ile SAM

SAM uygulamak için Tinkal, Kolemanit ve Uleksit için spektral imzaları ve Sentinel 2 uydu görüntüsünde hangi bant ve dalga boylarına karşılık geldiği Şekil 3.30 ve 3.31 gösterilmiştir.




Şekil 3.30. Sentinel 2 bantlarına göre bor minerallerinin yansımaya değerleri gösterimi



Şekil 3.31. Sentinel 2 bantlarının dalgaboylarına göre bor minerallerinin yansımaya değerleri gösterimi

Şekil 3.32’de görüldüğü üzere, Sentinel 2 uydu görüntüsü üzerinden Tinkal için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça siyah renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.32. *Sentinel 2 tinkal spektral aç haritalaması*

Şekil 3.33’de görüldüğü üzere, Sentinel 2 uydu görüntüsü üzerinden Kolemanit için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça kırmızı renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.




Şekil 3.33. *Sentinel 2 kolemanit spektral aç haritalaması*

Şekil 3.34’de görüldüğü üzere, Sentinel 2 uydu görüntüsü üzerinden üleksit gd138 için SAM uyguladığımız zaman Kırka Bor açık maden sahası açıkça yeşil renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.34. *Sentinel 2 uleksit gd138 spektral aç haritalaması*

Bor mineralleri için SAM uyguladığımız zaman su havzalarıyla yansıma değerleri karışabilmekte Kırka Bor açık maden sahası açıkça mavi renkte belirmekte, bununla birlikte su yüzeyleri de görünmektedir.



Şekil 3.35. *Sentinel 2 uleksit hd441 spektral aç haritalaması*

Bor mineralleri için SAM uyguladığımız zaman su havzalarıyla yansıma değerleri karışabilmekte Kırka Bor açık maden sahası ile birlikte su yüzeyleri de görünmektedir.

3.5.4. Temel bileşen analizi

Bor minerallerinin tespiti için Temel Bileşen Analizi (Principal Component Analysis - PCA) kullanımı, uzaktan algılama verilerini birkaç temel bileşene indirirken verinin varyansını en iyi temsil eden yeni bileşenler oluşturarak mineral belirginleşmesini sağlamaktadır.

Çalışma kapsamında temel bileşen analizi kullanılarak, Landsat8 ve Sentinel-2 görüntüleri için uygulandı. Uydu görüntülerinin VNIR ve SWIR bantları temel bileşen

analizi işlemine tabi tutuldu. Her görüntünün kovaryans matrisi oluşturularak özdeğer ve özvektörleri bulunarak temel bileşen analizi hesaplaması gerçekleştirildi.

3.5.4.1. Landsat8 görüntüleri ile PCA

PCA'nın temel amacı, orijinal değişkenlerin doğrusal kombinasyonlarından yeni bir koordinat sistemi oluşturmaktır. Bu süreçte her yeni eksen, Öz vektörü olarak adlandırılan bir vektörle temsil edilir ve eksenin önemi belirleyen bir öz değer alır. Öz değer, her ana bileşenin veri setindeki toplam varyansa ne kadar katkıda olduğunu gösterir. Landsat 8 uydu görüntüsüyle aldığımız öz değerler Tablo 3.3'te verilmiştir. Landsat 8 PCA kullanılırken B2 ile B7 bant aralığında bulunan bantlar kullanılmıştır.

Tablo 3.3. Öz değerler

Öz Değerler
0,034601
0,002924
0,000856
0,000079
0,000031
0,000012

Aynı şekilde öz değerler, her bileşen tarafından açıklanan varyans miktarını temsil eder. Varyans değerleri Tablo 3.4'te gösterilmiştir.

Tablo 3.4. PCA varyans oranı


Varyans Oranı	
PC1	89,87
PC2	7,59
PC3	2,22
PC4	0,2
PC5	0,08
PC6	0,03

Temel bileşen analizi sonucunda ortaya çıkan her bileşen ayrı ayrı Şekil 36-41'de gösterilmiştir. PC1 de Kırka bor açık maden ocağı belirgin bir şekilde ayır edilebilmekte, Bor mineralleri arasında ayırt etme konusunda zayıf kalmaktadır.




Şekil 3.36. *Landsat 8 temel bileşen analizi PC1*

PC2’de Kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebilmekte ve bor mineralleri kendi aralarında ayırt edilebilmektedir.



Şekil 3.37. *Landsat 8 temel bileşen analizi PC2*

PC3’de Kırka bor açık maden ocağının tamamı ayırt edilememektedir.




Şekil 3.38. *Landsat 8 temel bileşen analizi PC3*


PC4-5-6’da Kırka bor açık maden ocağı ayırt edilememektedir.



Şekil 3.39. *Landsat 8 temel bileşen analizi PC4*




Şekil 3.40. *Landsat 8 temel bileşen analizi PC5*



Şekil 3.41. *Landsat 8 temel bileşen analizi PC6*

Varyansı en yüksek olan ilk üç temel bileşenin sahte renk birleşimi gösterimiyle Şekil 3.42’de kırka maden ocağı belirgin şekilde ayırt edilip bor madenleri birbirisi arasında sınıflanabilmektedir.



Şekil 3.42. Landsat 8 temel bileşen analizi R:PC1,G:PC2,B:PC3

3.5.4.2. Sentinel-2 görüntüleri ile PCA

Sentinel 2 uydu görüntüsüyle aldığımız öz değerleri Tablo 3.5'te belirtilmiştir. Landsat 8 PCA kullanılırken B2 ile B7 bant aralığında bulunan bantlar kullanılmıştır.

Tablo 3.5. Öz değerler


Öz Değerler
0,073579
0,004693
0,002459
0,000275
0,000115
0,000043
0,000020
0,000018
0,000011
0,000007

Aynı şekilde öz değerler, her bileşen tarafından açıklanan varyans miktarını temsil eder. Varyans değerleri Tablo 3.6'da gösterilmiştir.

Tablo 3.6. *Varyans oranı*

Varyans Oranı	
PC1	90,59
PC2	6,78
PC3	3,03
PC4	0,34
PC5	0,14
PC6	0,05
PC7	0,03
PC8	0,02
PC9	0,01
PC10	0,01

Temel bileşen analizi sonucunda ortaya çıkan her bileşen ayrı ayrı Şekil 43-49’da gösterilmiştir. PC1 de Kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebilmekte, Bor mineralleri arasında ayırt etme konusunda zayıf kalmaktadır.




Şekil 3.43. *Sentinel 2 temel bileşen analizi PC1*

PC2’de Kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebilmekte ve bor mineralleri kendi aralarında ayırt edilebilmektedir.




Şekil 3.44. *Sentinel 2 temel bileşen analizi PC2*

PC3’de Kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebilmekte ve bor mineralleri kendi aralarında ayırt edilebilmektedir.



Şekil 3.45. *Sentinel 2 temel bileşen analizi PC3*

PC4-5-6’da Kırka bor açık maden ocağının tamamı ayırt edilememektedir.



Şekil 3.46. *Sentinel 2 temel bileşen analizi PC4*




Şekil 3.47. *Sentinel 2 temel bileşen analizi PC5*



Şekil 3.48. *Sentinel 2 temel bileşen analizi PC6*

Varyansı en yüksek olan ilk üç temel bileşenin sahte renk birleşimi gösterimiyle Şekil 3.49’de kırka maden ocağı belirgin şekilde ayırt edilip bor madenleri birbiri arasında sınıflanabilmektedir.



Şekil 3.49. *Sentinel 2 temel bileşen analizi R:PC1, G:PC2, B:PC3*

3.6. Kullanılan Makine Öğrenmesi Yöntemleri

Bu tez kapsamında aşağıda maddeler halinde belirtilen uzaktan algılamada kullanılan makine öğrenmesi yöntemleri kullanılarak bor minerali potansiyel haritaları oluşturulmuştur.

- Denetimsiz K-Means
- Denetimsiz LVQ
- Denetimli SVM
- Denetimli CART
- Denetimli Random Forest

Tez kapsamında uzaktan algılamada kullanılan makine öğrenmesi öncesinde aşağıdaki ön hazırlık adımları izlenmiştir.

- Atmosferik ve radyometrik düzeltmelerin yapılmış olan uydu görüntü kataloğunun seçimi,
- Bulutsuzluk oranı düşük uydu görüntülerinin seçimi,
- Çalışma alanı ve noktalarının belirlenmesi/gösterimi,
- Uydu görüntülerinde tam sayı olarak verilmiş yansıma değerlerinin gerçek yansıma değerlerine dönüştürülmesi.

3.6.1. Denetimsiz k-means


Uzaktan algılamada K-Means algoritması kullanımı, uzaktan algılama veri setinde benzer özelliklere sahip pikselleri kümeye (cluster) ayırmak için kullanılmaktadır. Bor mineralleri potansiyeli tespitinde K-Means algoritması benzer spektral özelliğe sahip grupları oluşturarak, bor mineral alanlarını belirginleştirmektedir.

Tez çalışması kapsamında K-means algoritması, Landsat 8 ve Sentinel 2 uydu görüntüleri için ayrı ayrı uygulandı. Bor mineralleriyle benzer özelliklere sahip kümeler oluşturuldu.


3.6.1.1. Landsat8 görüntüleri ile denetimsiz k-means

K-means, veriyi belirli sayıda kümeye ayırarak her küme için bir merkez belirler ve bu merkeze en yakın verileri bu kümeye dahil eder. K-means çalışması için öncelikli olarak bir eğitim seti oluşturmamız gerekiyor. Çalışma alanı içinde 5000 piksellik ve ölçeği 30 bir eğitim seti oluşturduk. Sınıf adedi 5 olan K-ortalamlar sonucu Şekil 3.50'de


sınıf adedi 10 olan K-ortalamlar sonucu Şekil 3.51’de 15 olan ise Şekil 3.52’de gösterilmiştir.



Şekil 3.50. *Landsat 8 K-ortalamlar (5 sınıf)*



Şekil 3.51. *Landsat 8 K-ortalamlar (10 sınıf)*



Şekil 3.52. *Landsat 8 K-ortalamlar (15 sınıf)*


Çalışma sonunda kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebiliyorken, bor minerallerin ayrımı da yapılabilmektedir.

3.6.1.2. Sentinel-2 görüntüleri ile denetimsiz k-means


Çalışma alanı içinde 5000 piksellik ve ölçeği 30 bir eğitim seti oluşturduk. Sınıf adedi 5 olan K-ortalamlar sonucu Şekil 3.53’de , sınıf adedi 10 olan K-ortalamlar sonucu Şekil 3.54’de 15 olan ise Şekil 3.55’de gösterilmiştir.



Şekil 3.53. Sentinel 2 K-ortalamlar (5 sınıf)



Şekil 3.54. Sentinel 2 K-ortalamlar (10 sınıf)



Şekil 3.55. Sentinel 2 K-ortalamlar (15 sınıf)

Çalışma sonunda kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebiliyorken, bor minerallerin ayrımı da yapılabilmektedir.


3.6.2. Denetimsiz LVQ

Learning Vector Quantization (LVQ), denetimsiz öğrenme tekniklerinden biri olup veri setindeki benzer veri noktalarını gruplamaktadır. Bor mineralleri potansiyeli tespitinde LVQ algoritması benzer spektral özelliğe sahip grupları oluşturarak, bor mineral alanlarını belirginleştirmektedir.


Tez çalışması kapsamında LVQ algoritması, Landsat 8 ve Sentinel 2 uydu görüntüleri için ayrı ayrı uygulandı. Bor mineralleriyle benzer özelliklere sahip kümeler oluşturuldu.

3.6.2.1. Landsat8 görüntüleri ile denetimsiz LVQ


Denetimsiz LVQ çalışması için ölçeği 30 ve piksel adedi 5000 bir eğitim seti oluşturuldu. Bu kapsamda sınıf adedi 5 olan öğrenmeli LVQ sonucu Şekil 3.56'da, sınıf adedi 10 olan 3.57'de, sınıf adedi 15 olan 3.58'de gösterilmiştir.



Şekil 3.56. Landsat 8 LVQ (5 sınıf)



Şekil 3.57. Landsat 8 LVQ (10 sınıf)




Şekil 3.58. *Landsat 8 LVQ (15 sınıf)*


Çalışma sonunda kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebiliyorken, bor minerallerin ayrımı da yapılabilmektedir.

3.6.2.2. Sentinel-2 görüntüleri ile denetimsiz LVQ


Denetimsiz LVQ çalışması için ölçeği 30 ve piksel adedi 5000 bir eğitim seti oluşturuldu. Bu kapsamda sınıf adedi 5 olan öğrenmeli LVQ sonucu Şekil 3.59’da , sınıf adedi 10 olan 3.60’de, sınıf adedi 15 olan 3.61’de gösterilmiştir.



Şekil 3.59. *Sentinel 2 LVQ (5 sınıf)*



Şekil 3.60. *Sentinel 2 LVQ (10 sınıf)*



Şekil 3.61. *Sentinel 2 LVQ (15 sınıf)*

Çalışma sonunda kırka bor açık maden ocağı belirgin bir şekilde ayırt edilebiliyorken, bor minerallerin ayrımı da yapılabilmektedir.


3.6.3. Destek vektör makineleri

Destek vektör makineleri (SVM), denetimli makine öğrenmesi yöntemi olup, uzaktan algılamada veri sınıflandırma ve regresyon problemleri için kullanılmaktadır. Bor minerali tespitinde SVM, önceden belirlenmiş bor minerali olan piksellerden oluşan etiketlenmiş spektral veri setleri kullanılmaktadır. Denetimli olarak sınıflandırılmış spektral veri etiketlerine göre benzer sınıfları içeren piksellere aynı etiketleri vererek sınıflandırmaktadır.


Tez çalışması kapsamında, bundan önce yapılan çalışmaların, açık maden ocağı verileri kullanılarak, Landsat 8 ve Sentinel 2 uydu görüntüleri için ayrı ayrı eğitim ve test veri seti oluşturuldu. SVM algoritması, Landsat 8 ve Sentinel 2 uydu görüntüleri için uygulanarak potansiyel bor mineral alanları için bir harita oluşturuldu.

3.6.3.1. Landsat8 görüntüleri ile SVM

Makine öğrenmesi veri ve validasyon setinin oluşturulması için geçmiş çalışmalar ve bölgede bilinen noktalar seçilerek bir eğitim ve validasyon seti oluşturuldu. Şekil 3.62 oluşturulan eğitim ve validasyon veri seti noktalarını göstermektedir. Oluşturulan eğitim seti pca ve denetimsiz sınıflandırmalarla kontrol edilerek uygunluğu teyit edildi. Şekil 3.63 oluşturulan eğitim ve validasyon noktaları denetimsiz sınıflama ile oluşan sınıflarla karşılaştırılarak tutarlılığı kontrol edildi. Bor minerali olup olmama durumu ve bor mineralleri sınıfları olmak üzere iki ayrı eğitim grubu oluşturuldu.




Şekil 3.62. Eğitim ve validasyon seti noktaları



Şekil 3.63. Eğitim ve validasyon seti için tutarlılık kontrolü

Bor olup olmama durumu üzerine yapılan sınıflandırmada şekil 3.64'te bor minerali bulunan bölgelerin sınırı belirgin şekilde bulunmuştur.



Şekil 3.64. Landsat 8 kullanarak bor minerali bulunan bölgelerin SVM ile gösterilmesi

3.6.3.2. Sentinel-2 görüntüleri ile SVM

Landsat 8'e oluşturulan eğitim ve validasyon setlerinin benzerleri sentinel içinde tekrar oluşturuldu. Bor olup olmama durumu üzerine yapılan sınıflandırmada Şekil 3.65'te bor minerali bulunan bölgelerin sınırı belirgin şekilde bulunmuştur.



Şekil 3.65. Sentinel 2 kullanarak bor minerali bulunan bölgelerin SVM ile gösterilmesi

3.6.4. Sınıflandırma ve regresyon ağaçları

Classification and Regression Trees (CART), uzaktan algılamada veri sınıflandırma ve regresyon problemleri için kullanılan güçlü ve esnek bir denetimli öğrenme yöntemidir. Temelinde bağımlı değişkenin kategorik veya sürekli olmasına bağlı olarak sınıflandırma veya regresyon ağaçları üreten parametrik olmayan bir karar ağacı öğrenme tekniğidir. CART, eğitim seti verilen spektral veri etiketlerine göre benzer sınıfları içeren piksellere aynı etiketleri vererek sınıflandırma yapmaktadır.

3.6.4.1 Landsat8 görüntüleri ile CART

Bundan önce oluşturulmuş eğitim veri setleri kullanılarak bor olup olmama durumuna göre yapılan sınıflandırmada Şekil 3.66'da bor minerali bulunan bölgelerin sınırı az belirgin şekilde bulunmuştur.



Şekil 3.66. Landsat 8 kullanarak bor minerali bulunan bölgelerin CART ile gösterilmesi

3.6.4.2 Sentinel 2 görüntüleri ile CART

Bundan önce oluşturulmuş eğitim veri setleri kullanılarak bor olup olmama durumuna göre yapılan sınıflandırmada Şekil 3.67’de bor minerali bulunan bölgelerin sınırı az belirgin şekilde bulunmuştur.



Şekil 3.67. Sentinel 2 kullanarak bor minerali bulunan bölgelerin CART ile gösterilmesi


3.6.5. Rasgele orman

Random Forest (RF), birçok karar ağacından oluşan güçlü bir denetimli öğrenme algoritmasıdır. Bu algoritma, birden fazla karar ağacını yani ormanı bir araya getirerek çalışan ve her ağacın çıktısını oylama alma yoluyla birleştiren bir topluluk öğrenme yöntemidir. RF, bor minerallerinin tespitinde spektral verileri sınıflandırmak için etkili bir şekilde kullanılabilir.

Bor minerali tespitinde RF, önceden belirlenmiş bor minerali olan piksellerden oluşan etiketlenmiş spektral veri setleri kullanılmaktadır. Denetimli olarak sınıflandırılmış spektral veri etiketlerine göre benzer sınıfları içeren piksellere sınıflandırmaktadır.

3.6.5.1 Landsat 8 görüntüleri ile RF


Bundan önce oluşturulmuş eğitim veri setleri kullanılarak bor olup olmama durumuna göre yapılan sınıflandırmada Şekil 3.68’de bor minerali bulunan bölgelerin sınırı az belirgin şekilde bulunmuştur.



Şekil 3.68. *Landsat 8 kullanarak bor minerali bulunan bölgelerin RF ile gösterilmesi*

3.6.5.2 Sentinel 2 görüntüleri ile RF


Bundan önce oluşturulmuş eğitim veri setleri kullanılarak bor olup olmama durumuna göre yapılan sınıflandırmada Şekil 3.69’da bor minerali bulunan bölgelerin sınırı az belirgin şekilde bulunmuştur.



Şekil 3.69. *Sentinel 2 kullanarak bor minerali bulunan bölgelerin RF ile gösterilmesi*


3.7. Bor Kaşifi

Tez konusu ile ilgili yapılan çalışmaları hiç bu konuda bilgisi olmayan birinin bile kullanabileceği basitlikte Bor kaşifi adlı bir yazılım aracı geliştirildi. Bu yazılım Google Earth engine altyapısını kullanarak Doktora tezi konusundaki çalışmaların kullandırılması amaçlanmaktadır. Bor Kaşifinin çalışma metodolojisi Şekil 3.70’de verilmiştir.



Şekil 3.70. Bor kâşifi akışı

Bor kâşifi, uzaktan algılama yöntemleri kullanarak bor potansiyel tahmin haritaları çıkartmak için belirli değişkenleri kullanıcı tarafından belirlenerek yapıldığı, bu konuda derin deneyimi veya tecrübesi olmadan, özel bir yazılıma gerek duymadan yapan Google Earth Engine tabanlı bir araçtır. Şekil 3.71’de örnek bir arayüzü gösterilmiştir.



Şekil 3.71. *Bor kâşifi arayüz*

Bor kaşifinde ilk önce çalışılmak istenen uydu seçilir. (Şekil 3.72) Halihazırda iki adet uydu tipi tanımlanmıştır. Bunlar; Landsat 8 ve Sentinel 2 dir.

Şekil 3.72. *Uydu seçimi*

Kullanılacak Uydu Belirlendikten sonra başlangıç ve bitiş tarihleri arasında hangi uydu görüntülerinin istendiği talep edilir. (Şekil 3.73) Bu uydu görüntülerini çekerken merkeze göre sınırlandırma getirilebilir. Ayrıca yapılan bu filtreleme işleminde uydu görüntüleri için bulut düzeltmesi otomatik olarak yapılmış olanlar getirilir.

Google Earth Engine

Bor Kaşifi v0.2

Bu uygulama uydu Görüntüleri üzerinden Bor aramaya yardımcı olmayı sağlar. Merkez olarak çalışma alanı olan KIRKA (30.46678, 39.2937) tercih edilmiştir. Bölge (30.46756, 39.30712, 30.51733, 39.2751) siyah renk ile gösterilmiştir.

1) Uydu Seç

LANDSAT 8

LANDSAT 8 Surface Reflectance

2) Filtre Seç

Başlangıç tarihi
2017-05-01

Bitiş Tarihi
2017-05-31

☒ Merkeze göre Filtre Uygula

Filtre Uygula

Şekil 3.73. Tarih seçimi

Filtre uygula butonuna basılmasıyla beraber üçüncü olan uydu görüntüsü seçimi yapılır. (Şekil 3.74) Birden fazla seçilmesi durumunda uydu görüntülerinin ortalama değerini alacaktır. Merkeze getir butonuna basıldığında uydu görüntüsünün kapsadığı alanı merkeze alacak şekilde haritayı büyütür.

Google Earth Engine

Bor Kaşifi v0.2

Bu uygulama uydu Görüntüleri üzerinden Bor aramaya yardımcı olmayı sağlar. Merkez olarak çalışma alanı olan KIRKA (30.46678, 39.2937) tercih edilmiştir. Bölge (30.46756, 39.30712, 30.51733, 39.2751) siyah renk ile gösterilmiştir.

1) Uydu Seç

LANDSAT 8

LANDSAT 8 Surface Reflectance

2) Filtre Seç

Başlangıç tarihi
2017-05-01

Bitiş Tarihi
2017-05-31

☒ Merkeze göre Filtre Uygula

Filtre Uygula

3) Görüntü Seç

LC08_178033_20170508
LC08_178033_20170524
LC08_179033_20170515

Şekil 3.74. Görüntü seçimi

Uydu Görüntüleri seçildikten sonra getirilen uydu görüntüsünün ön tanımlı hangi görselleştirme yöntemiyle gösterileceğini seçimi yapılır.

Google Earth Engine

Bor Kaşifi v0.2

Bu uygulama uydu Görüntüleri üzerinden Bor aramaya yardımcı olmayı sağlar. Merkez olarak çalışma alanı olan KIRKA (30.46678, 39.2937) tercih edilmiştir. Bölge (30.46756, 39.30712, 30.51733, 39.2761) siyah renk ile gösterilmiştir.

1) Uydu Seç

LANDSAT 8

LANDSAT 8 Surface Reflectance

2) Filtre Seç

Başlangıç tarihi
2017-05-01

Bitiş Tarihi
2017-05-31

☒ Merkeze göre Filtre Uygula

Filtre Uygula

3) Görüntü Seç

LC08_178033_20170508

Merkeze Getir

4) Uydu Görselleştirilmesi

Sahte Renk (B7/B6/B4)

Gerçek Renk (B4/B3/B2)

Atmosferik (B7/B6/B5)

Şekil 3.75. Görüntü görselleştirme

Şekil 3.76 gösterildiği üzere çalıştırılmak istenen algoritma seçilir ve ön tanımlı ayarlarına göre algoritma çalışır ve sonuç haritasını gösterir. Dışarıya aktarma butonuyla da yapılan çalışmanın sonuçları kayıt altına alınabilir.

Bor Kaşifi v0.2

Bu uygulama uydu Görüntüleri üzerinden Bor aramaya yardımcı olmayı sağlar. Merkez olarak çalışma alanı olan KIRKA (30.46678, 39.2937) tercih edilmiştir. Bölge (30.46756, 39.30712, 30.51733, 39.2761) siyah renk ile gösterilmiştir.

1) Uydu Seç

LANDSAT 8

LANDSAT 8 Surface Reflectance

2) Filtre Seç

Başlangıç tarihi
2017-05-01

Bitiş Tarihi
2017-05-31

☒ Merkeze göre Filtre Uygula

Filtre Uygula

3) Görüntü Seç

LC08_178033_20170508

Merkeze Getir

4) Uydu Görselleştirilmesi

Sahte Renk (B7/B6/B4)

Bitkiler kırmızının renkleri, yerleşim yerleri mavitoprak kahverengidir.

5) Method Seç

BAND RATIO

UNSUPERVISED KMEANS

UNSUPERVISED LVQ

ML CART

ML RANDOM FOREST

ML SVM

Şekil 3.76. Algoritma seçimi

4. SONUÇLAR VE ÖNERİLER

Uzaktan algılama analiz yöntemleri kullanılarak uydu görüntüleri ile bor madeni arama ve araştırma üzerine kısıtlı olsa da çalışmalar bulunmaktadır. Çalışmada bor minerallerini arama süreçlerini hızlandırmak ve iyileştirmek için uzaktan algılama teknolojilerinin gücünden yararlanılmıştır.

Yapılan çalışmalar sonucunda, çalışma alanında bor minerallerinin uzaktan algılama yöntemleri, denetimsiz makine öğrenmesi ve denetimli makine öğrenmesi teknikleri karşılaştırılarak kullanılmıştır. Bu çalışma kapsamında, Landsat-8 ve Sentinel-2 uydu verileri kullanılarak Kırka Bor Açık Ocak alanının ayırt edilebilirliği ve bor minerallerinin sınırlarının belirlenebilirliği üzerine yapılan detaylı bir analizi sunmaktadır. Uydu görüntülerinin uzaktan algılama yöntemleri, denetimsiz makine öğrenmesi ve denetimli makine öğrenmesi yöntemleri ile işlenmesi, alanın farklı özelliklerinin ortaya çıkarılmasına olanak sağlamıştır. Analizler sonucunda, sırasıyla denetimli destek vektör makineleri, denetimli rasgele orman, denetimli sınıflandırma ve regresyon ağaçları ve denetimsiz öğrenmeli vektör kuantalama bor minerali ayrımı yapılabilmektedir (Tablo 4.1).

Borun nadir bulunan bir maden olması nedeni ile uzaktan algılama yöntemleri ile bor konusundaki çalışmalar oldukça azdır. Bu sebepten çalışma bor minerali üzerine yapılmış bir çok alt çalışmayı kapsamakta ve bu bağlamda bor minerallerinin uzaktan algılama kullanılarak ayırımına yönelik yapılacak ileri araştırmalar için önemli bir referans niteliğindedir.

Tablo 4.1. Makine öğrenmesi karşılaştırma

Makine Öğrenmesi Yöntemi	Uydu	Yöntem	Kırka Bor Açık Ocak Ayırt Edilebilirliği	Bor Mineralleri Ayırma Yapılabilirliği/Sınırların Belirlenebilirliği
Sahne Renk Bölümleri	Landsat-8	Bant 6-5-4	Hatalar ile ayırt edilebilmekte	Bölgeler için farklı renk farklılıkları oluşmaktadır
		Bant 7-5-5	Hatalar ile ayırt edilebilmekte	Bölgeler için farklı renk farklılıkları oluşmaktadır
	Sentinel-2	Bant 12-8A-4	Hatalar ile ayırt edilebilmekte, Landsat8 gösterimine göre daha az hata ile ayırt edilebilmekte	landsat8 gösterimine göre daha az hata ile bölgeler için farklı renk farklılıkları oluşmaktadır
		Bant 11-12-8A	Hatalar ile ayırt edilebilmekte, Landsat8 gösterimine göre daha az hata ile ayırt edilebilmekte	landsat8 gösterimine göre daha az hata ile bölgeler için farklı renk farklılıkları oluşmaktadır
		Bant 11-8-2	Hatalar ile ayırt edilebilmekte, Landsat8 gösterimine göre daha az hata ile ayırt edilebilmekte	landsat8 gösterimine göre daha az hata ile bölgeler için farklı renk farklılıkları oluşmaktadır
		Bant5/Bant7	İşletimin havuz alanını göstermekte ve açık maden ocağıyla ilgili kısıtlı bilgi vermektedir	Ayrım yapılamamaktadır
Bant Orantıları	Landsat-8	Bant4/Bant7	İşletimin havuz alanını net bir şekilde görülmekte ve maden alanı içinde bazı alanlar belirginleşmektedir	Ayrım yapılamamaktadır
		Bant5/Bant4	Su yüzeyleri ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		Sahne Renk Bölümü	Su yüzeyleri ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
	Sentinel-2	Bant11/Bant5	Su yüzeyleri ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		Bant7/Bant5	Su yüzeyleri ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		Bant12/Bant5	Su yüzeyleri ve diğer yüzeyler ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		Sahne Renk Bölümü	Su yüzeyleri ile karışmaktadır, hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		Spektral Açık Haritalama	Landsat-8	Su yüzeyleri ile karışmaktadır, bant orantılamaya göre daha az hata ile ayırt edilebilmekte
Sentinel-2	Su yüzeyleri ile karışmaktadır, bant orantılamaya göre daha az hata ile ayırt edilebilmekte		Ayrım yapılamamaktadır	
Temel Bölge Analizi	Landsat-8	PC1	Ayırt edilebilmekte	Kuşlarda olma bilgi vermektedir
		PC2	Ayırt edilebilmekte	Kuşlarda olma bilgi vermektedir
		PC3	Ayırt edilememekte	Ayrım yapılamamaktadır
		PC4	Ayırt edilememekte	Ayrım yapılamamaktadır
		PC5	Ayırt edilememekte	Ayrım yapılamamaktadır
		PC6	Ayırt edilememekte	Ayrım yapılamamaktadır
	Sentinel-2	Sahne Renk Bölümü	Ayırt edilebilmekte	Kuşlarda olma bilgi vermektedir
		PC1	Ayırt edilebilmekte	Kuşlarda olma bilgi vermektedir
		PC2	Ayırt edilebilmekte	Kuşlarda olma bilgi vermektedir
		PC3	Hatalar ile ayırt edilebilmekte	Ayrım yapılamamaktadır
		PC4	Ayırt edilememekte	Ayrım yapılamamaktadır
		PC5	Ayırt edilememekte	Ayrım yapılamamaktadır
Denetimsiz K-Ortalamlar	Landsat-8	5 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
		10 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
		15 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
	Sentinel-2	5 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
		10 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
		15 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
Denetimsiz Öğrenmeli Vektör Kuantalama	Landsat-8	5 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
		10 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
		15 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
	Sentinel-2	5 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
		10 Sınıf	Ayırt edilebilmekte	Kuşlarda olma ayırma yapılabilmekte
		15 Sınıf	Ayırt edilebilmekte	Ayrım yapılamamaktadır
Denetimli Destek Vektör Makineleri	Landsat-8		Ayırt edilebilmekte	Bölgelerin sınırı belirgin
	Sentinel-2		Ayırt edilebilmekte	Bölgelerin sınırı belirgin
Denetimli Sınıflandırma ve Regresyon Ağaçları	Landsat-8		Ayırt edilebilmekte	Bölgelerin sınırı az belirgin
	Sentinel-2		Ayırt edilebilmekte	Bölgelerin sınırı az belirgin
Denetimli Rasgele Orman	Landsat-8		Ayırt edilebilmekte	Bölgelerin sınırı az belirgin
	Sentinel-2		Ayırt edilebilmekte	Bölgelerin sınırı az belirgin

Bu kapsamda farklı uydulara ait farklı zamanlarda uydu görüntüleri farklı gösterim teknikleri ve farklı uzaktan algılama yöntemleri ve makine öğrenme teknikleri kullanarak incelenmesine olanak sağlayan Bor Kaşifi adında bir yazılım geliştirilmiştir. Bu yazılım ve kullanılan yöntem ve/veya yöntemlerle az veri seti bulunan bor mineralleri araştırmalarında uzman deneyimi olmayan kişilerin bu alanda analiz ve çalışma yapmasına olanak sağlayacaktır. Bulunan modeller çalışma alanı dışında kalan herhangi bir coğrafi bölgede geliştirilen yazılım ve yöntemler kullanılarak tahminlemede bulunabilecektir. Bor madeni araştırmaları için primitif bir araçta olsa bunun otomatize edilmesi anlamında öncü olacağı bor minerali dışında birçok maden araştırmasında da bu anlamda öncülük edecektir.

Bor mineralinin stratejik bir maden olması sebebiyle verilere erişimdeki sıkıntılar ve kısıtlardan dolayı çalışmanın farklı veri setleri ve makine öğrenmesi pekiştirme algoritmalarıyla iyileştirilmesi daha doğru sonuçlar verecektir.

KAYNAKÇA

- Atkinson, P. M., and Tatnall, A. R. L. (1997). Introduction neural networks in remote Sensing. *International Journal of Remote Sensing*, 18(4), 699-709.
- Ayday, C., Bayat, O., and Kaya, G. (2014). *Borates: Handbook of Deposits, Processing, Properties, and Use*. 2nd Edition. Academic Press.
- Azamathulla, H. M. (2012). Gene-expression programming for sediment transport in open channels. *Journal of Hydroinformatics*, 14(3), 542-552.
- Azamathulla, H. M., and Ghani, A. A. (2011). Genetic programming for predicting the longitudinal dispersion coefficients in streams. *Environmental Fluid Mechanics*, 11(2), 229-241.
- Azamathulla, H. M., Ghani, A. A., and Chang, C. K. (2012). Genetic programming to predict bridge pier scour. *Journal of Hydraulic Engineering*, 138(10), 948-954.
- Azamathulla, H. M., Wu, F. C., and Ghani, A. A. (2011). Support vector machine approach for longitudinal dispersion coefficients in natural streams. *Applied Soft Computing*, 11(2), 2902-2905.
- Baatz, M., and Schäpe, A. (2000). Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Angewandte Geographische Informationsverarbeitung XII*, 58-68.
- Bendig, J., Bolten, A., and Bareth, G. (2015). UAV-based imaging for multi-temporal, very high resolution crop surface models to monitor crop growth variability. *Photogrammetrie - Fernerkundung - Geoinformation*, 2015(6), 551-562.
- Bonham-Carter, G. F. (1994). *Geographic Information Systems for Geoscientists: Modelling with GIS*. Pergamon.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32
- Brown, M., Gunn, S. R., Lewis, H. G., and Jones, R. (2008). Support vector machines for environmental management: A brief review. *Environmental Modelling & Software*, 23(4), 395-402.
- Campbell, J. B. (1996). *Introduction to Remote Sensing* (2nd ed.). New York, NY: Guilford Press.
- Camps-Valls, G. (2009). *Remote Sensing and Machine Learning for Environmental Monitoring*.
- Camps-Valls, G., and Bruzzone, L. (2009). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), 1351-1362.
- Carpenter, G. A., Gajja, M. N., Gopal, S., and Woodcock, C. E. (1997). ART neural networks for remote sensing: Vegetation classification from Landsat TM and terrain data. *IEEE Transactions on Geoscience and Remote Sensing*, 35(2), 308- 325.

- Carranza, E. J. M. (2008). *Geochemical Anomaly and Mineral Prospectivity Mapping in GIS*. Elsevier.
- Cheng, Q., and Agterberg, F. P. (1999). Fuzzy weights of evidence method and its application in mineral potential mapping. *Natural Resources Research*, 8(1), 27-35.
- Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., and Lambin, E. (2004). Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, 25(9), 1565-1596.
- Çölkesen, İ. (2009). Decision tree classifiers for land cover classification. *International Journal of Remote Sensing*, 30(3), 703-721.
- Çölkesen, M. (2015). *Makine Öğrenmesi ve Uygulamaları*. Papatya Yayıncılık.
- Das, S. K., and Basudhar, P. K. (2008). Prediction of residual friction angle of clays using artificial neural network. *Engineering Geology*, 100(3-4), 142-145.
- Du, P., Liu, S., Xia, J., Zhao, Q., and Zhang, H. (2009). Fusion of difference images for change detection over urban areas. *IEEE Transactions on Geoscience and Remote Sensing*, 47(7), 2237-2248.
- Du, P., Xia, J., Zhang, W., Tan, K., Liu, Y., and Liu, S. (2012). Multiple classifier system for remote sensing image classification: A review. *Sensors*, 12(4), 4764-4792.
- Foody, G. M., Boyd, D. S., and Sanchez-Hernandez, C. (2006). Mapping a specific class with an ensemble of classifiers. *International Journal of Remote Sensing*, 27(20), 4175-4187.
- Garg, A., Tai, K., and Sivakumar, B. (2014a). A comparative study of particle swarm optimization and genetic algorithm for soil modeling. *Journal of Hydrology*, 511, 238-251.
- Garg, A., Tai, K., and Sivakumar, B. (2014b). Evolutionary algorithms for soil modeling. *Applied Soft Computing*, 22, 237-247.
- Garg, A., Tai, K., and Sivakumar, B. (2014c). Optimization techniques for soil classification. *Journal of Intelligent Learning Systems and Applications*, 6(2), 154-165.
- Gibson, P. J. (2000). *Introductory Remote Sensing: Principles and Concepts*. Routledge.
- Goodchild, M. F. (2017). Traditional database systems with advanced geographic tools. In P. A. Longley, M. F. Goodchild, D. J. Maguire, and D. W. Rhind (Eds.), *Geographic Information Science and Systems* (4th ed.). Wiley.
- Gómez-Chova, L., Alonso-Chorda, L., and Camps-Valls, G. (2005). Unsupervised Learning Vector Quantization for Remote Sensing Data Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 622-634.
- Helvacı, C., and Alonso, R. N. (2000). Borate deposits of Turkey and Argentina: A summary and geological comparison. *Turkish Journal of Earth Sciences*, 9(1), 1-27.

- Hu, Y., Weng, Q., and Liu, H. (2010). Estimating impervious surfaces using linear spectral mixture analysis with multitemporal ASTER images. *International Journal of Remote Sensing*, 31(1), 45-59.
- Huang, C., Davis, L. S., and Townshend, J. R. G. (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4), 725-749.
- Jensen, J. R. (2005). *Introductory Digital Image Processing: A Remote Sensing Perspective* (3rd ed.). Prentice Hall.
- Jensen, J. R. (2016). *Introductory Digital Image Processing: A Remote Sensing Perspective*. Pearson.
- Jooshaki, E., Behnia, M., and Ramezankhani, A. (2021). Application of Machine Learning in Mineral Exploration and Mining. [Journal/Conference Paper Title]. [Journal/Conference Name].
- Kavzoğlu, T., and Çölkesen, I. (2010). An assessment of the effectiveness of a rotation forest ensemble for land-use and land-cover mapping. *Photogrammetric Engineering & Remote Sensing*, 76(8), 965-974.
- Kavzoğlu, T., and Çölkesen, I. (2012). The effects of training set size for performance of support vector machines and decision trees. *Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium*, 4310-4313.
- Kavzoğlu, T., and Çölkesen, I. (2013). An assessment of the effectiveness of a rotation forest ensemble for land-use and land-cover mapping. *Photogrammetric Engineering & Remote Sensing*, 79(9), 885-894.
- Kunwar, R., and others. (2010). Remote sensing techniques for monitoring and assessment of desertification: a review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(5), 497-507.
- Lai-ping, M. (2007). Application of CART Algorithm in Remote Sensing for Environmental Monitoring and Resource Management. [Journal/Conference Name].
- Lary, D. J., Alavi, A. H., Gandomi, A. H., and Walker, A. L. (2004). Machine learning in geosciences and remote sensing. *Geoscience and Remote Sensing*, 7(1), 3-29.
- Lillesand, T. M., and Kiefer, R. W. (2004). *Remote Sensing and Image Interpretation* (5th ed.). Wiley.
- Liu, D., Pattey, E., and Miller, J. R. (2006). Assessing the impact of scale on the relationship between leaf area index and spectral vegetation indices. *Remote Sensing of Environment*, 99(4), 409-424.
- Lu, D., and Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28.
- Mather, P. M., and Koch, M. (2011). *Computer Processing of Remotely-Sensed Images: An Introduction* (4th ed.). Wiley.

- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Muhammad, F., and Saepuloh, A. (2016). *Spectral Angle Mapping for Mineral Identification Using Remote Sensing Data*. [Conference Paper/Journal Article].
- Pal, M., and 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.
- Pal, M., and Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007-1011.
- Palmer, M. R., and Helvacı, C. (1997). The genesis of the Kırka borate deposit, western Turkey. *Chemical Geology*, 137(1-2), 89-101.
- Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann.
- Rayar, A., Smith, J., and Johnson, L. (2023). Electromagnetic Spectrum Analysis and Applications. *Journal of Remote Sensing*, 45(3), 123-145.
- Richards, J. A., and Jia, X. (2013). *Remote Sensing Digital Image Analysis: An Introduction*. Springer.
- Sabins, F. F. (1987): *Remote sensing – Principles and Interpretation*. W.H. Freeman & Co., 2 edn., 449 p.
- Safavian, S. R., and Landgrebe, D. (1991). A survey of decision tree classifier methodology. *IEEE Transactions on Systems, Man, and Cybernetics*, 21(3), 660-674.
- Schulz, K., Ludwig, R., and Mauser, W. (2018). *Remote Sensing and Digital Image Analysis*. Springer.
- Singer, D. A. (1993). *Basic concepts in three-part quantitative assessments of undiscovered mineral resources*. *Nonrenewable Resources*, 2(2), 69-81.
- Sigurdsson, H., Johnsson, P., and Smith, A. (2022). Makale Başlığı. *Dergi Adı*, 22(3), 123-145.
- Sunar, F., and Özkan, C. (2018). *Uzaktan Algılama ve Coğrafi Bilgi Sistemleri*. Nobel Akademik Yayıncılık.
- Swain, P. H., and Hauska, H. (1977). The decision tree classifier: Design and potential. *IEEE Transactions on Geoscience Electronics*, 15(3), 142-147.
- Tempfli, K., Kerle, N., Huurneman, G. C., and Janssen, L. L. F. (Eds.). (2009). *Principles of Remote Sensing: An introductory textbook*. ITC Educational Textbook Series 2. Enschede, The Netherlands: The International Institute for Geo-Information Science and Earth Observation (ITC)
- Tout, K., and Littin, C. (2004). *An Overview of Remote Sensing Methods and Techniques*.
- Virnodkar, S. S., Kumbhar, N. N., and Talbar, S. N. (2020). Application of Machine Learning Techniques in Agricultural Crop Yield Prediction and Water Stress Detection. [Journal/Conference Paper Title]. [Journal/Conference Name].

Wen, X., Yang, X., and Zhang, Y. (2008). Application of CART algorithm in remote sensing image classification. Proceedings of the International Conference on Computer Science and Software Engineering, 1, 1245-1248.

Yılmaz, A., and Kaya, M. (2015). Nesnelerin dalga boylarına göre karakteristikleri. Elektrik Mühendisliği Dergisi, 35(4), 123-130.

http-1: https://commons.wikimedia.org/wiki/File:Planck_law_log_log_scale.png
(Erişim tarihi:01.06.2024)

http-2: <https://www.usgs.gov/media/images/landsat-8-band-designations> (Erişim tarihi: 01.06.2024)

http-3: <https://en.wikipedia.org/wiki/Sentinel-2> (Erişim tarihi: 01.06.2024)



EKLER

Borate Explorer Yazılım Kodları

//Borate explorer Versiyon 1.0

//Ender Kelleci

//Uygulama yarat

var app = { };

//UI panelleri yaratma fonksiyonu

app.createPanels = function() {

app.intro = {

panel: ui.Panel([

ui.Label({

value: 'Bor Kaşifi v1.0',

style: {fontWeight: 'bold', fontSize: '24px', margin: '10px 5px'}

}),

ui.Label('Bu uygulama uydu Görüntüleri üzerinden Bor potansiyeli aramaya ' +

'yardımcı olmayı sağlamaktadır..'+'\n'+ ' Merkez olarka çalışma alanı olan KIRKA (30.46678, 39.2937) tercih edilmiştir. Bölge (30.46756, 39.30712, 30.51733, 39.2751) siyah renk ile gösterilmiştir.')

])

};

app.satpicker = {

label: ui.Label(),

```
// Seçime göre değişim olayını tetikle

select: ui.Select({

    items: Object.keys(app.COL_ID_OPTIONS),

    onChange: function() {

        var option = app.COL_ID_OPTIONS[app.satpicker.select.getValue()];

        app.satpicker.label.setValue(option.description);

    }

})

};

//Uydu Seçim paneli

app.satpicker.panel = ui.Panel({

widgets: [

    ui.Label('1) Uydu Seç', {fontWeight: 'bold'}),

    app.satpicker.select,

    app.satpicker.label

],

style: app.SECTION_STYLE

});

//Uydu görüntüsü filtre ayarları

app.filters = {

    mapCenter: ui.Checkbox({label: 'Merkeze göre Filtre Uygula', value: true}),

    startDate: ui.Textbox('YYYY-MM-DD', '2022-09-01'),

    endDate: ui.Textbox('YYYY-MM-DD', '2022-09-30'),

    applyButton: ui.Button('Filtre Uygula', app.applyFilters),
```

```
loadingLabel: ui.Label({
    value: 'Yükleniyor...',
    style: {stretch: 'vertical', color: 'gray', shown: false}
})

};

//Filter için panel ayarları

app.filters.panel = ui.Panel({
widgets: [
    ui.Label('2) Filtre Seç', {fontWeight: 'bold'}),
    ui.Label('Başlangıç tarihi', app.HELPER_TEXT_STYLE), app.filters.startDate,
    ui.Label('Bitiş Tarihi ', app.HELPER_TEXT_STYLE), app.filters.endDate,
    app.filters.mapCenter,
    ui.Panel([
        app.filters.applyButton,
        app.filters.loadingLabel
    ], ui.Panel.Layout.flow('horizontal'))
],
style: app.SECTION_STYLE
});

//Uydu görüntüsü seçme

app.picker = {
    select: ui.Select({
        placeholder: 'Uydu Görüntüsü Seç',
        onChange: app.refreshMapLayer
```

```
    }),  
  
    // Merkeze Getirme  
  
    centerButton: ui.Button('Merkeze Getir', function() {  
        Map.centerObject(Map.layers().get(0).get('eeObject'));  
    })  
  
};  
  
//Görüntü Seçme Paneli  
  
app.picker.panel = ui.Panel({  
    widgets: [  
        ui.Label('3) Görüntü Seç', {fontWeight: 'bold'}),  
        ui.Panel([  
            app.picker.select,  
            app.picker.centerButton  
        ], ui.Panel.Layout.flow('horizontal'))  
    ],  
  
    style: app.SECTION_STYLE  
});  
  
//Algoritma Seçme  
  
app.methodpicker = {  
    label: ui.Label(),  
    select: ui.Select({  
        items: Object.keys(app.METHOD_OPTIONS),  
        onChange: function(selected) {applyFilters_RSA(selected);  
    }  
}
```

```
    })

};

//Algoritma Seçme Paneli

app.methodpicker.panel = ui.Panel({

widgets: [

    ui.Label('5) Method Seç', { fontWeight: 'bold' }),

    app.methodpicker.select,

    app.methodpicker.label

],

style: app.SECTION_STYLE

});

//Gösterim Seçme

app.vis = {

    label: ui.Label(),

    select: ui.Select({

        items: Object.keys(app.VIS_OPTIONS),

        onChange: function() {

            var option = app.VIS_OPTIONS[app.vis.select.getValue()];

            app.vis.label.setValue(option.description);

            app.refreshMapLayer();

        }

    })

};
```

```
//Gösteirm Seçme Paneli

app.vis.panel = ui.Panel({

widgets: [

    ui.Label('4) Uydu Görselleştirilmesi', { fontWeight: 'bold'}),

    app.vis.select,

    app.vis.label

],

style: app.SECTION_STYLE

});

//Default değer olarak ilk değeri seçme

app.vis.select.setValue(app.vis.select.items().get(0));

app.satpicker.select.setValue(app.satpicker.select.items().get(0));

//Dışa Aktar

app.export = {

button: ui.Button({

    label: 'Çalışmayı Dışarıya Aktar',

    onClick: function() {

        var imageIdTrailer = app.picker.select.getValue();

        var imageId = app.COL_ID_OPTIONS[app.satpicker.select.getValue()].satParams

+ '/' + imageIdTrailer;

        // Gösterim seçeneklerini al

        var visOption = app.VIS_OPTIONS[app.vis.select.getValue()];

        // Drive'a aktar

        Export.image.toDrive({
```

```

        image: ee.Image(imageId).select(visOption.visParams.bands),

        description: 'L8_Export-' + imageIdTrailer,

    });

}

}))

};

//Dışarı aktarma paneli

app.export.panel = ui.Panel({

widgets: [

    ui.Label('(6) Dışarıya Aktar', {fontWeight: 'bold'}),

    app.export.button

],

style: app.SECTION_STYLE

});

};

//Yardımcı Fonksiyonlar

app.createHelpers = function() {

    //yüklemeyi aktfi et

    app.setLoadingMode = function(enabled) {

        // Yüklenirken etiketleri göster

        app.filters.loadingLabel.style().set('shown', enabled);

        //bütün panelleri yükle

        var loadDependentWidgets = [

            app.vis.select,

```

```
    app.satpicker.select,
    app.methodpicker.select,
    app.filters.startDate,
    app.filters.endDate,
    app.filters.applyButton,
    app.filters.mapCenter,
    app.picker.select,
    app.picker.centerButton,
    app.export.button
];

loadDependentWidgets.forEach(function(widget) {
    widget.setDisabled(enabled);
});

};

//Yüklenirken filtreleri uygula

app.applyFilters = function() {
    app.setLoadingMode(true);

    var filtered = ee.ImageCollection(app.COL_ID_OPTIONS[app.satpicker.select.getValue()].satParams);

    filtered = filtered.filterBounds(workarea24);

    // Filtre değerlerini ata

    var start = app.filters.startDate.getValue();
    var end = app.filters.endDate.getValue();
```

```

        filtered                =                filtered.filterDate(app.filters.startDate.getValue(),
app.filters.endDate.getValue());//.map(app.maskL8sr);

// Filtreye göre liste getir

var computedIds = filtered

    .limit(app.IMAGE_COUNT_LIMIT)

    .reduceColumns(ee.Reducer.toList(), ['system:index'])

    .get('list');

computedIds.evaluate(function(ids) {
app.setLoadingMode(false);
app.picker.select.items().reset(ids);

    app.picker.select.setValue(app.picker.select.items().get(0));

    Map.addLayer(ee.Image().paint(workarea24, 0, 2), { }, 'workarea24');

});

});

//haritayı güncelle

app.refreshMapLayer = function() {

Map.clear();

var imageId = app.picker.select.getValue();

if (imageId) {

    //Görüntü bulunmazsa

        var                image                =

ee.Image(app.COL_ID_OPTIONS[app.satpicker.select.getValue()].satParams + '/' +
imageId);

    //Gösterim seçeneklerini uygulam

var visOption = app.VIS_OPTIONS[app.vis.select.getValue()];

```

```
Map.addLayer(image, visOption.visParams, imageId);

}

};

};

//Uygulama sabitleri

app.createConstants = function() {

    //app.COLLECTION_ID = 'LANDSAT/LC08/C01/T1_RT_TOA';

    app.SECTION_STYLE = {margin: '20px 0 0 0'};

    app.HELPER_TEXT_STYLE = {

        margin: '8px 0 -3px 8px',

        fontSize: '12px',

        color: 'gray'

    };

    app.IMAGE_COUNT_LIMIT = 10;

    app.VIS_OPTIONS = {

        'Gerçek Renk (B4/B3/B2)': {

            description: 'Gözle görüldüğüne yakın bir gösterim sağlar',

            visParams: {gamma: 1.3, min: 4000, max: 36000, bands: ['SR_B4', 'SR_B3',

'SR_B2']}]

        },

        'Sahte Renk (B7/B6/B4)': {

            description: 'Bitkiler kırmızının renkleri, yerleşim yerleri mavi' +

                'toprak kahverengidir.',

            visParams: {gamma: 1.3, min: 1000, max: 3000, bands: ['SR_B7', 'SR_B6', 'SR_B4']}]

        }

    }

}
```

```
},
'Atmosferik (B7/B6/B5)': {
  description: 'Kıyı ve Sahli şeridi' +
    'bitkiler mavi görünümündedir.',
  visParams: { gamma: 1.3, min: 0, max: 3000, bands: ['SR_B7', 'SR_B6', 'SR_B5']}
}
};

app.COL_ID_OPTIONS = {
  'LANDSAT 8': {
    description: 'LANDSAT 8 Surface Reflectance',
    satParams: 'LANDSAT/LC08/C02/T1_L2'
  },
  'SENTINEL 2': {
    description: 'SENTINEL 2',
    satParams: 'COPERNICUS/S2'
  }
}
};

app.METHOD_OPTIONS = {
  'FALSE COLOR COMPOSITE': {
    description: 'BAND ORANLAMA Yöntemi',
    satParams: 'FCC'
  },
  'BAND RATIO': {
    description: 'BAND ORANLAMA Yöntemi',
```

```
satParams: 'BR'

},

'SAM': {

  description: 'BAND ORANLAMA Yöntemi',

  satParams: 'SAM'

},

'PCA': {

  description: 'BAND ORANLAMA Yöntemi',

  satParams: 'PCA'

},

'UNSUPERVISED KMEANS': {

  description: 'DENETİMSİZ KMEANS SINIFLANDIRMA Yöntemi',

  satParams: 'KMEANS'

},

'UNSUPERVISED LVQ': {

  description: 'DENETİMSİZ ÖĞRENMELİ VECTOR KUANTALAMA Kullanarak Sınıflandırma',

  satParams: 'LVQ'

},

'ML CART': {

  description: 'SINIFLANDIRMA VE REGRESYON AĞAÇLARI Kullanılarak Sınıflandırma',

  satParams: 'CART'

},
```

```
'ML RANDOM FOREST': {  
  description: 'RASSAL ORMAN Yöntemi Kullanılarak Sınıflandırma',  
  satParams: 'FOREST'  
},  
  
'ML SVM': {  
  description: 'KARAR DESTEK MAKİNELERİ Yöntemi Kullanılarak Sınıflandırma',  
  satParams: 'SVM'  
}  
};  
  
};  
  
//Bulut maskeleye değerini ayarla  
app.maskL8sr=function(image) {  
  // Bits 3 and 5 are cloud shadow and cloud, respectively.  
  
  var cloudShadowBitMask = (1 << 3);  
  
  var cloudsBitMask = (1 << 5);  
  
  // Get the pixel QA band.  
  
  var qa = image.select('pixel_qa');  
  
  // Both flags should be set to zero, indicating clear conditions.  
  
  var mask = qa.bitwiseAnd(cloudShadowBitMask).eq(0)  
    .and(qa.bitwiseAnd(cloudsBitMask).eq(0));  
  
  return image.updateMask(mask);  
};  
  
//Uygulama Arayüzünü oluştur
```

```
app.boot = function() {  
  
    //Sabirleri çağır  
  
    app.createConstants();  
  
    //Yardımcıları çağır  
  
    app.createHelpers();  
  
    //Panelleri yarat  
  
    app.createPanels();  
  
    var main = ui.Panel({  
        widgets: [  
            app.intro.panel,  
            app.satpicker.panel,  
            app.filters.panel,  
            app.picker.panel,  
            app.vis.panel,  
            app.methodpicker.panel,  
            app.export.panel  
        ],  
        style: { width: '320px', padding: '8px' }  
    });  
  
    Map.setCenter(30.46678, 39.2937, 14);  
  
    ui.root.insert(0, main);  
  
    app.applyFilters();  
  
};  
  
// Uygulama Arayüzünü başlat
```

```

app.boot();

/*

Algoritma Fonksiyonları

*/

//Uzaktan Algılama Algoritmasının Seçilmesi

function applyFilters_RSA(selected) {

    var imageId = app.picker.select.getValue();

    if (imageId) {

        var landsatdata = ee.Image(app.COL_ID_OPTIONS[app.satpicker.select.getValue()].satParams + '/' + imageId);

        var visOption = app.VIS_OPTIONS[app.vis.select.getValue()];

        Map.clear();

        if (selected == 'BAND RATIO') {

            print('BR');

            bandRatioHL (landsatdata,workarea24);

        } else if (selected == 'SAM') {

            SAMHL(landsatdata,workarea24);

        }else if (selected == 'FCC') {

            FCCHL(landsatdata,workarea24);

        }else if (selected == 'PCA') {

            PCAHL(landsatdata);

        }else if (selected == 'UNSUPERVISED LVQ') {

            LVQHL(landsatdata);

```

```
}else if (selected == 'ML SVM') {  
    SVMHL(landsatdata);  
}  
else if (selected == 'ML CART') {  
    CARTHL(landsatdata);  
}  
}  
}  
  
//Landsat uydusu için ölçek değerlerini uygula  
function applyScaleFactorsLS(image) {  
    var opticalBands = image.select('SR_B.').multiply(0.0000275).add(-0.2);  
    return image.addBands(opticalBands, null, true);  
}  
  
//Bant Orantılama Genel Fonksiyonu  
function bandRatio(SatImage,band1,band2){  
    var image= SatImage.expression(  
        'band1 / band2', {  
            'band1': SatImage.select(band1),  
            'band2': SatImage.select(band2)});  
    return image;  
}  
  
//Bant Orantılama  
function bandRatioHL (landsatdata,workarea24){  
    print('BandRatioHL');  
    Map.centerObject(kirkamaden, 10);
```

```

var editlenenveri = applyScaleFactorsLS(landsatdata).clip(workarea24);

Map.addLayer(editlenenveri,{ bands:'SR_B4,SR_B3,SR_B2'},'LANDSAT8 SF');

var bandratio57=bandRatio(editlenenveri,'SR_B5','SR_B7').rename('BR57');

var bandratio47=bandRatio(editlenenveri,'SR_B4','SR_B7').rename('BR47');

var bandratio54=bandRatio(editlenenveri,'SR_B5','SR_B4').rename('BR54');

var bandratio=bandratio57.addBands(bandratio47.select('BR47'));

bandratio=bandratio.addBands(bandratio54.select('BR54'));


Map.addLayer(bandratio57,{ min:4,max:5},'BANT ORANTILAMA Bant 5/7');

Map.addLayer(bandratio47,{ min:1.5,max:2.5},'BANT ORANTILAMA Bant 4/7');

Map.addLayer(bandratio54,{ min:0,max:1.3},'BANT ORANTILAMA Bant 5/4');

Map.addLayer(bandratio,{ min:1,max:1.5,bands:'BR57,BR54,BR47'},'BANT
ORANTILAMA');

}

//Temel Bileşen Analizi Genel Fonksiyonu

function PCA(maskedImage){

var image = maskedImage.unmask();

var scale = 20;

var region = workarea24;

var bandNames = image.bandNames();

print(bandNames);

// Mean center the data to enable a faster covariance reducer

// and an SD stretch of the principal components.

var meanDict = image.reduceRegion({

```

```

    reducer: ee.Reducer.mean(),

    geometry: region,

    scale: scale,

    maxPixels: 1e9,

    bestEffort: true,

    tileScale: 16

  });

var means = ee.Image.constant(meanDict.values(bandNames));
var centered = image.subtract(means);

// This helper function returns a list of new band names.
var getNewBandNames = function(prefix) {

  var seq = ee.List.sequence(1, bandNames.length());

  return seq.map(function(b) {

    return ee.String(prefix).cat(ee.Number(b).int());

  });

};

//Temel Bileşen Analizi Fonksiyonu

var getPrincipalComponents = function(centered, scale, region) {

  // Collapse the bands of the image into a 1D array per pixel.

  var arrays = centered.toArray();

  // ComCovaryans hesapla

  var covar = arrays.reduceRegion({

    reducer: ee.Reducer.centeredCovariance(),

    geometry: region,

```

```

    scale: scale,

    maxPixels: 1e9,

    bestEffort: true,

    tileScale: 16

});

var covarArray = ee.Array(covar.get('array'));

print('CovarArray', covarArray);

// Eigen Değerleri

var eigens = covarArray.eigen();

var eigenValues = eigens.slice(1, 0, 1);

print('eigenvalues', eigenValues);

var eigenValuesList = eigenValues.toList().flatten();

var total = eigenValuesList.reduce(ee.Reducer.sum());

var percentageVariance = eigenValuesList.map(function(item) {

    return (ee.Number(item).divide(total)).multiply(100).format('% .2f');

});

print('Percentage Variance of Each Component', percentageVariance);

var eigenVectors = eigens.slice(1, 1);

var arrayImage = arrays.toArray(1);

var principalComponents = ee.Image(eigenVectors).matrixMultiply(arrayImage);

var sdImage = ee.Image(eigenValues.sqrt())

    .arrayProject([0]).arrayFlatten([getNewBandNames('sd')]);

return principalComponents

    .arrayProject([0])

```

```

        .arrayFlatten([getNewBandNames('pc')])

        .divide(sdImage);

    };

    var pcImage = getPrincipalComponents(centered, scale, region);

    return pcImage.mask(maskedImage.mask());

}

function PCAHL(landsatdata){
    print(landsatdata);
    var editlenenveri = applyScaleFactorsLS(landsatdata);
    var pcaveri=editlenenveri.select('SR_B2','SR_B3','SR_B4','SR_B5','SR_B6','SR_B7');
    var pcaAll = PCA(pcaveri);
    print(pcaAll);
    var pca=pcaAll.select('pc1', 'pc2', 'pc3');
    Map.addLayer(pcaAll,"','PCA_ALL');
    Map.addLayer(pca, {bands: ['pc1', 'pc2', 'pc3']}, 'pca');
    Map.addLayer(pcaveri, {bands: ['SR_B4', 'SR_B3', 'SR_B2']}, 'pca_Composite');
}

function LVQ (input, region){
    // eğitim veri seti oluştur

    var training = input.sample({
    region: region,
    scale: 30,
    numPixels: 5000

```

```

});

var clusterer = ee.Clusterer.wekaLVQ(15, 1, 10, true).train(training)

var result = input.cluster(clusterer);

print (result);

return result;

}

function LVQHL(landsatdata){

Map.centerObject(kirkamaden, 10);//unsupervisedLVQ

var landsat8 = applyScaleFactorsLS(landsatdata);

var lvqimage=LVQ(landsat8,workarea24);

var palettes = require('users/gena/packages:palettes');

var palette = palettes.misc.tol_rainbow[7];

Map.addLayer(landsat8,{bands:'SR_B4,SR_B3,SR_B2'},'LANDSAT8 SF');

Map.addLayer(ee.Image().paint(workarea24, 0, 2), { }, 'region');

Map.addLayer(lvqimage,

    { min: 0, max: 14, palette: palette },

    'classify');

Map.addLayer(lvqimage.randomVisualizer(), { }, 'clusters');

}

function SVM(input,region,borMP,borNonMP,borVMP,borVNonMP,bands){

    // Eğitim verilerini birleştirme

var trainingPoints = borMP.merge(borNonMP);

var validationPoints = borVMP.merge(borVNonMP);

var trainingData = input.select(bands).sampleRegions({

```

```
collection: trainingPoints,

properties: ['class'],

scale: 30

});

var validationData = input.select(bands).sampleRegions({

collection: validationPoints,

properties: ['class'],

scale: 30

});

// SVM sınıflandırıcısını oluşturma ve eğitme

var svmClassifier = ee.Classifier.libsvm().train({

features: trainingData,

classProperty: 'class',

inputProperties: bands

});

print('Results of trained classifier', svmClassifier.explain());

var trainAccuracy = svmClassifier.confusionMatrix();

print('Training error matrix', trainAccuracy);

print('Training overall accuracy', trainAccuracy.accuracy());

var validationSample = validationData.classify(svmClassifier);

print(validationSample);

var validationAccuracy = validationSample.errorMatrix('class', 'classification');

print('Validation error matrix', validationAccuracy);

print('Validation accuracy', validationAccuracy.accuracy());
```

```
print('Kappa statistic', trainAccuracy.kappa());

// Görüntüyü sınıflandırma

var result = input.select(bands).classify(svmClassifier);

print (result);

return result;

}

function spectralchart(satimage, chartpoints,bands,wavelengths,title1,titile2){

var COLOR = {

  KIRKA: 'ff0000',

  //FARM: '0000ff',

  //URBAN: '00ff00'

};

var fvgPoints = chartpoints;

print(fvgPoints);

var fvgImage = ee.Image(satimage);

// Select bands B1 to B7.

fvgImage = fvgImage.select(bands);

var bandChart = ui.Chart.image.regions({

  image: fvgImage,

  regions: fvgPoints,

  scale: 30,

  seriesProperty: 'label'

});

bandChart.setChartType('LineChart');
```

```
bandChart.setOptions({  
    title: title1,  
    hAxis: {  
        title: 'Bant'  
    },  
    vAxis: {  
        title: 'Yansıma'  
    },  
    lineWidth: 1,  
    pointSize: 4,  
    series: {  
        0: {color: COLOR.KIRKA},  
        //1: {color: COLOR.FARM},  
        //2: {color: COLOR.URBAN}  
    }  
});  
  
var spectraChart = ui.Chart.image.regions({  
    image: fvgImage,  
    regions: fvgPoints,  
    scale: 30,  
    seriesProperty: 'class',  
    xLabels: wavelengths  
});  
  
spectraChart.setChartType('LineChart');
```

```
spectraChart.setOptions({  
    title: 'title2',  
    hAxis: {  
        title: 'Dalgaboyu (micrometers)'  
    },  
    vAxis: {  
        title: 'Yansima'  
    },  
    lineWidth: 1,  
    pointSize: 4,  
    series: {  
        0: {color: COLOR.KIRKA},  
        //1: {color: COLOR.FARM},  
        //2: {color: COLOR.URBAN}  
    }  
});  
  
print(bandChart);  
print(spectraChart);  
  
}  
  
function addLegend() {  
    var legend = ui.Panel({  
        style: {  
            position: 'bottom-left',  
            padding: '8px 15px'
```

```
    }  
  });  
  
  var legendTitle = ui.Label({  
    value: 'Lejant',  
    style: {  
      fontWeight: 'bold',  
      fontSize: '18px',  
      margin: '0 0 4px 0',  
      padding: '0'  
    }  
  });  
  
  legend.add(legendTitle);  
  
  var makeRow = function(color, name) {  
    var colorBox = ui.Label({  
      style: {  
        backgroundColor: color,  
        padding: '8px',  
        margin: '0 0 4px 0'  
      }  
    });  
  
    var description = ui.Label({  
      value: name,  
      style: { margin: '0 0 4px 6px' }  
    });  
  }
```

```

return ui.Panel({

  widgets: [colorBox, description],

  layout: ui.Panel.Layout.Flow('horizontal')

});

};

var palette = ['#000000', '#FF0000', '#00FF00', '#0000FF']; // Renk paleti

var names = ['Tinkal', 'Kolemanit', 'Uleksit GDS138', 'Uleksit HD441']; // Sınıf isimleri

for (var i = 0; i < palette.length; i++) {

  legend.add(makeRow(palette[i], names[i]));

}

Map.add(legend);

}

function CART(input, region, borMP, borNonMP, bands){

  // Eğitim verilerini birleştirme

  var trainingPoints = borMP.merge(borNonMP);

  var trainingData = input.sampleRegions({

    collection: trainingPoints,

    properties: ['class'],

    scale: 10

  });

  // Random Forest Modeli Eğitimi

  var cartclassifier = ee.Classifier.smileCart().train({

    features: trainingData,

```

```
classProperty: 'class',

inputProperties: bands

});

// Görüntüyü sınıflandırma

var result = input.select(bands).classify(cartclassifier);

print (result);

return result;

}

function SVMHL(landsatdata){

Map.centerObject(kirkamaden, 10);

var landsatbands = ['SR_B1','SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'];

var landsatwl = [0.44, 0.48, 0.56, 0.65, 0.86, 1.61, 2.2];

var landsatdata = landsatdata.clip(workarea24).select(landsatbands);

print(landsatdata);

var landsat8 = applyScaleFactorsLS(landsatdata);

spectralchart(landsat8, TrainingDataBor,landsatbands,landsatwl,'Eğitim Seti Noktaların
Landast 8 SR Bant Değerleri','Eğitim Seti Noktaların Landast 8 SR Dalga Boyu
Değerleri');

spectralchart(landsat8, ValidationDataBor,landsatbands,landsatwl,'Validasyon Seti
Noktaların Landast 8 SR Bant Değerleri','Validasyon Seti Noktaların Landast 8 SR Dalga
Boyu Değerleri');

spectralchart(landsat8, Tinkal,landsatbands,landsatwl,'Tinkal Noktaların Landast 8 SR
Bant Değerleri','Tinkal Noktaların Landast 8 SR Dalga Boyu Değerleri');

spectralchart(landsat8, Tinkalval,landsatbands,landsatwl,'Tinkal Validasyon Noktaların
Landast 8 SR Bant Değerleri','Tinkal Validasyon Noktaların Landast 8 SR Dalga Boyu
Değerleri');
```

```
spectralchart(landsat8, Kolemanit,landsatbands,landsatwl,'Kolemanit Noktaların Landast 8 SR Bant Değerleri','Kolemanit Noktaların Landast 8 SR Dalga Boyu Değerleri');
```

```
spectralchart(landsat8, KolemanitVal,landsatbands,landsatwl,'Kolemanit Validasyon Noktaların Landast 8 SR Bant Değerleri','Kolemanit Validasyon Noktaların Landast 8 SR Dalga Boyu Değerleri');
```

```
spectralchart(landsat8, Uleksit,landsatbands,landsatwl,'Uleksit Noktaların Landast 8 SR Bant Değerleri','Uleksit Validasyon Noktaların Landast 8 SR Dalga Boyu Değerleri');
```

```
spectralchart(landsat8, UleksitVal,landsatbands,landsatwl,'Uleksit Validasyon Noktaların Landast 8 SR Bant Değerleri','Uleksit Validasyon Noktaların Landast 8 SR Dalga Boyu Değerleri');
```

```
var TrainingBor=Tinkal.merge(Kolemanit).merge(Uleksit);
```

```
var TrainingBorVal=Tinkalval.merge(KolemanitVal).merge(UleksitVal);
```

```
var
```

```
svmresult=SVM(landsat8,workarea24,TrainingBor,TrainingDataNotBor,TrainingBorVal,ValidationDataNotBor,landsatbands);
```

```
var
```

```
svmresult2=SVM(landsat8,workarea24,TrainingDataBor,TrainingDataNotBor,ValidationDataBor,ValidationDataNotBor,landsatbands);
```

```
// Harita üzerinde görüntüleme
```

```
var palettes = require('users/gena/packages:palettes');
```

```
var palette = palettes.misc.tol_rainbow[7];
```

```
Map.addLayer(landsat8.select(landsatbands),{ bands:'SR_B4,SR_B3,SR_B2'},'LANDSAT8 SF');
```

```
Map.addLayer(ee.Image().paint(workarea24, 0, 2), {}, 'region');
```

```
Map.addLayer(svmresult2,
```

```
  { min: 0, max: 0.5, palette: ['black', 'white']},
```

```
  'classify');
```

```

Map.addLayer(svmresult2.randomVisualizer(), {}, 'clusters');

Map.addLayer(svmresult,

    { min: 0, max: 32, palette:palette},

    'classify');

Map.addLayer(svmresult.randomVisualizer(), {}, 'clusters');

}

function CARTHL(landsatdata){

// Eğitim verilerini oluşturma

var borMineralPoints = TrainingData;

var nonBorMineralPoints = TrainingDataNotBor;

Map.centerObject(kirkamaden, 10);

//var                landsatdata                =

ee.Image('LANDSAT/LC08/C02/T1_L2/LC08_179033_20220918').clip(workarea24);

print(landsatdata);

var landsat8 = applyScaleFactorsLS(landsatdata);

var landsatbands = ['SR_B1','SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'];

var landsatwl = [0.44, 0.48, 0.56, 0.65, 0.86, 1.61, 2.2];

spectralchart(landsat8, Kolemanit,landsatbands,landsatwl);

var cartresult=CART(landsat8,workarea24,Tinkal,nonBorMineralPoints,landsatbands);

// Harita üzerinde görüntüleme

var palettes = require('users/gena/packages:palettes');

var palette = palettes.misc.tol_rainbow[7];

Map.addLayer(landsat8.select(landsatbands),{ bands:'SR_B4,SR_B3,SR_B2'},'LANDS

AT8 SF');

```

```
Map.addLayer(ee.Image().paint(workarea24, 0, 2), {}, 'region');

Map.addLayer(cartresult,
  {min: 0, max: 0.5, palette: ['black', 'white']},
  'classify');

Map.addLayer(cartresult.randomVisualizer(), {}, 'clusters');
}
```



ÖZGEÇMİŞ

ORCID NO: 0009-0000-7331-7744

Ad Soyad : Ender KELLEÇİ

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2005, Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik- Elektronik Mühendisliği Bölümü
- 2009, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik- Elektronik Mühendisliği, Kontrol Kumanda Sistemleri Bilim Dalı
- 2005, Coğrafi Bilgi Sistemleri Uzmanı ve Yazılım Geliştiricisi, Belnet Bilişim ve San. Ltd. Şti.
- 2007, Müdür, ESTRAM Ulaşım San ve Tic. AŞ., Yönetim Bilgi Sistemleri
- 2013, Coğrafi Bilgi Sistemleri Uzmanı, Eskişehir Büyükşehir Belediyesi, Bilgi İşlem Daire Başkanlığı
- 2014, Kurucu, ÇözümTR Ödeme Sistemleri A.Ş.

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- 2011, Yazar, Konumsal Veritabanı, Anadolu Üniversitesi Yayınları, ISBN:978-975-06-1015-8, Eskişehir
- 2011, Yazar, Veritabanına Giriş, Anadolu Üniversitesi Yayınları, ISBN:978-975-06-1025-7, Eskişehir

Mesleki Birlik/Dernek/Kuruluş Üyelikleri:

- 2005, Elektrik Mühendisleri Odası, Ankara
- 2005, Eskişehir Osmangazi ve Anadolu Üniversitesi Elektrik Elektronik Mezunları Derneği, Eskişehir
- 2009, Türkiye Linux Kullanıcıları Derneği, Ankara