

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**OPTİK VE RADAR UZAKTAN ALGILAMA GÖRÜNTÜLERİ
KULLANILARAK LİTOLOJİK BİRİMLERİN FARKLI SINIFLANDIRMA
TEKNİKLERİ İLE KARŞILAŞTIRILMASI**

Hatice Seval MANAP

FEN BİLİMLERİ ENSTİTÜSÜ

JEOLOJİ MÜHENDİSLİĞİ

ANABİLİM DALI

DOKTORA TEZİ

HAZİRAN 2022

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OPTİK VE RADAR UZAKTAN ALGILAMA GÖRÜNTÜLERİ
KULLANILARAK LİTOLOJİK BİRİMLERİN FARKLI SINIFLANDIRMA
TEKNİKLERİ İLE KARŞILAŞTIRILMASI**

**Hatice Seval MANAP
JEOLJİ MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ**

**Bu tez Akdeniz Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi
tarafından FDK-2018-3875 nolu proje ile desteklenmiştir.**

HAZİRAN 2022

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OPTİK VE RADAR UZAKTAN ALGILAMA GÖRÜNTÜLERİ
KULLANILARAK LİTOLOJİK BİRİMLERİN FARKLI SINIFLANDIRMA
TEKNİKLERİ İLE KARŞILAŞTIRILMASI

Hatice Seval MANAP
JEOLOJİ MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ

Bu tez 22/06/2022 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof. Dr. Bekir Taner SAN	[imza]
Prof. Dr. Namık Kemal SÖNMEZ	[imza]
Prof. Dr. Hakan Ahmet NEFESLİOĞLU	[imza]
Prof. Dr. Kaan Şevki KAVAK	[imza]
Doç. Dr. Yasemin LEVENTELİ	[imza]

ÖZET

OPTİK VE RADAR UZAKTAN ALGILAMA GÖRÜNTÜLERİ KULLANILARAK LİTOLOJİK BİRİMLERİN FARKLI SINIFLANDIRMA TEKNİKLERİ İLE KARŞILAŞTIRILMASI

Hatice Seval MANAP

Doktora Tezi, Jeoloji Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Bekir Taner SAN

Haziran 2022; 78 sayfa

Bu çalışmada Antalya'nın batısında kalan Batı Torosları içine alan bölgenin uzaktan algılama verilerinden optik görüntüleri (ASTER), Polarimetrik Sentetik Açıklıklı Radar (SAR) görüntüleri (Sentinel-1) ve sayısal yükseklik modeli (DEM) verilerinden yararlanılarak litolojik haritalaması yapılmıştır. Sınıflandırma yöntemlerinden maksimum benzerlik sınıflandırması, makine öğrenme algoritmalarından destek vektör makinaları ve rastgele orman ile derin öğrenme algoritması olan yapay sinir ağları sınıflandırmalarının kullanılması ve bunların birbirleri ile karşılaştırılması amaçlanmıştır. Optik ve radar uzaktan algılama verileri ile DEM verileri farklı kombinasyonlarda birleştirilerek oluşturulan girdi veri setleri, farklı sınıflandırıcı algoritmaları ile sınıflandırılmıştır.

Bu tez çalışması kapsamında Kemer ve çevresini içine alan pilot bölgede kayaçların detay mineral tayini için, ince kesitlerin farklı açılarda görüntüleri alınarak sınıflandırması da yapılmıştır. Elde edilen mineral oranlarından spektral karışımlar üretilmiştir. Bu spektral karışımlardan türetilen spektral imzalar ve mevcut spektral kayaç kütüphanesinden elde edilen spektral imzalar kullanılarak Spektral Açık Haritalayıcı (SAM) analizi yapılmış ve sonrasında litolojik sınıflandırmalar da üretilmiştir. Tüm analizlere ilişkin sonuçlar, mevcut jeoloji haritası ve arazi gözlemleri ile karşılaştırılarak, doğruluk analizi yapılarak neticelendirilmiştir.

ANAHTAR KELİMELER: Antalya, ASTER, Litolojik Sınıflandırma, Makine Öğrenme Algoritması, Sentinel-1

JÜRİ: Prof. Dr. Bekir Taner SAN

Prof. Dr. Namık Kemal SÖNMEZ

Prof. Dr. Hakan Ahmet NEFESLİOĞLU

Prof. Dr. Kaan Şevki KAVAK

Doç. Dr. Yasemin LEVENTELİ

ABSTRACT

COMPARISON OF LITHOLOGICAL UNITS WITH DIFFERENT CLASSIFICATION TECHNIQUES USING OPTICAL AND RADAR REMOTE SENSING IMAGES

Hatice Seval MANAP

PhD Thesis in Department of Geological Engineering

Supervisor: Prof. Dr. Bekir Taner SAN

June 2022; 78 pages

In this study, the lithological mapping of the region to the west of Antalya, including the Western Taurus Mountains, was made using optical images (ASTER), polarimetric SAR images (Sentinel-1) and digital elevation model (DEM) data from remote sensing data. It was aimed to use maximum similarity classification from classification methods, support vector machines from machine learning algorithms and artificial neural networks classifications as random forest and deep learning algorithms and to compare them with each other. The input data sets generated by combining optical and radar remote sensing data with DEM data in different combinations are classified with different classification algorithms.

Within the scope of this thesis, the images of the thin sections at different angles were taken and their classification was also performed for the detailed mineral determination of the rocks in the pilot region of Kemer and its surroundings. Spectral mixtures were produced from the obtained mineral ratios. Spectral Angle Mapper (SAM) analyses were performed using the spectral signatures generated from spectral mixtures and spectral signatures of the existing spectral libraries of rocks, and then lithological classifications also produced. The results of all analyses were compared with the existing geological map and field observations and concluded by performing accuracy analysis.

KEYWORDS: Antalya, ASTER, Lithological Classification, Machine Learning Algorithm, Sentinel-1

COMMITTEE: Prof. Dr. Bekir Taner SAN

Prof. Dr. Namık Kemal SÖNMEZ

Prof. Dr. Hakan Ahmet NEFESLİOĞLU

Prof. Dr. Kaan Şevki KAVAK

Assoc. Prof. Dr. Yasemin LEVENTELİ

ÖNSÖZ

“Optik ve Radar Uzaktan Algılama Görüntüleri Kullanılarak Litolojik Birimlerin Farklı Sınıflandırma Teknikleri ile Karşılaştırılması” başlıklı hazırlanmış olan bu çalışma, 2017-2022 yılları arasında Akdeniz Üniversitesi Fen Bilimleri Enstitüsü Jeoloji Mühendisliği Anabilim Dalında doktora tezi olarak hazırlanmıştır. Doktora tez çalışmamı FDK-2018-3875 numaralı proje ile destekleyen Akdeniz Üniversitesi Bilimsel Araştırma Proje Birimine teşekkür ederim.

Tezimin yer ve konu seçiminden başlayarak her aşamasında yanımda olan ve yardımcı olan, doktora eğitimim boyunca bilgilerini, zamanını ve tecrübesini benimle paylaşan, yol gösteren, ufkumu açan ve motive eden değerli hocam Prof. Dr. Bekir Taner San’a çok teşekkür ederim.

Değerli yorum, öneri ve görüşleriyle tezime yön veren tez izleme komitesi üyesi sayın Prof. Dr. Namık Kemal Sönmez ve sayın Prof. Dr. Hakan Ahmet Nefeslioğlu hocalarıma teşekkür ederim. Tezimin son şeklini almasında yardımcı olan sayın Prof. Dr. Kaan Şevki Kavak ve Doç. Dr. Yasemin Leventeli hocalarıma teşekkür ederim.

Litolojik birimlerin ayrımlarını yaparak gruplandırmamda bana yardımcı olan arkadaşım Jeo. Müh. Dr. Ferdi Demirtaş’a, mikroskop incelemelerimde yardımcı olan Prof. Dr. Tamer Koralay’a, Prof. Dr. Erdal Koşun’a, Prof. Dr. Nurdane İlbeyli’ye ve yazım aşamasındaki yardımlarından dolayı Arş. Gör. Dr. Fatih Uçar’a teşekkür ederim.

Sadece doktora tezimde değil akademik çalışmalarımın tümünde arazi çalışmalarımda beni yalnız bırakmayan, göstermiş olduğu sabır ve verdiği desteklerden dolayı eşim Yük. Kimyager Ömer Manap’a, hayatımın her aşamasında yanımda olan beni idare eden oğlum Kerem Manap’a ve anne babama sonsuz teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ.....	1
1.1. Çalışmanın Amacı	1
1.2. Çalışmanın Kapsamı	2
2. KAYNAK TARAMASI.....	5
3. MATERYAL VE METOT.....	9
3.1. Materyal	9
3.2. Metot	12
3.2.1. Maksimum Benzerlik Haritası	17
3.2.2. Rastgele Orman	18
3.2.3. Destek Vektör Makinaları	19
3.2.4. Yapay Sinir Ağları	20
3.2.5. Spektral Açık Haritalaması	22
3.2.6. Spektral Karışım Analizi	23
3.2.7. Sonuçların doğruluk analizi	25
4. BULGULAR	28
4.1. Ast Veri Setinde MLC Sınıflandırması	28
4.2. Ast Veri Setinde RF Sınıflandırması.....	29
4.3. Ast Veri Setinde SVM Sınıflandırması	30
4.4. Ast Veri Setinde ANN Sınıflandırması	31
4.5. AstSen Veri Setinde MLC Sınıflandırması	32
4.6. AstSen Veri Setinde RF Sınıflandırması.....	33
4.7. AstSen Veri Setinde SVM Sınıflandırması	34
4.8. AstSen Veri Setine ANN Sınıflandırması	35
4.9. AstDem Veri Setine MLC Sınıflandırması	36
4.10. AstDem Veri Setine RF Sınıflandırması.....	37

4.11. AstDem Veri Setine SVM Sınıflandırması.....	38
4.12. AstDem Veri Setine ANN Sınıflandırması.....	39
4.13. AstSenDem Veri Setine MLC Sınıflandırması.....	40
4.14. AstSenDem Veri Setine RF Sınıflandırması.....	41
4.15. AstSenDem Veri Setine SVM Sınıflandırması.....	42
4.16. AstSenDem Veri Setine ANN Sınıflandırması.....	43
4.17. Kemer Bölgesinde SAM Uygulaması.....	44
4.18. Kemer Bölgesinde SMA Uygulaması.....	44
4.19. Doğruluk Analizi Sonuçları	45
5. TARTIŞMA.....	55
6. SONUÇLAR	61
7. KAYNAKLAR.....	62
8. EKLER.....	71
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “Optik ve Radar Uzaktan Algılama Görüntüleri Kullanılarak Litolojik Birimlerin Farklı Sınıflandırma Teknikleri ile Karşılaştırılması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

22/06/2022

Hatice Seval MANAP

SİMGELER VE KISALTMALAR

Simgeler

%	: Yüzde
km	: Kilometre
km ²	: Kilometrekare
m	: Metre
μ	: Mikron
°	: Derece

Kisaltmalar

ANN	: Yapay Sinir Ağları Sınıflandırması (Artificial Neural Network)
ASD	: Spektrometre ölçüm cihazı (Analytical Spectral Devices)
ASTER	: Advanced Spaceborne Thermal Emission and Reflection Radiometer
Ast	: ASTER uydusunun 14 bantlı veri seti
AstDem	: ASTER görüntüsü ve DEM birleşimi veri seti
AstSen	: ASTER görüntüsü ve Sentinel-1 verisinin birleşimi veri seti
AstSenDem	: ASTER, DEM ve Sentinel-1 verilerinin birleşimi veri seti
CBS	: Coğrafi Bilgi Sistemleri
DEM	: Sayısal Yükseklik Modeli (Digital Elevation Model)
ESA	: Avrupa Uzay Ajansı
Frqz	: Frekans
GB	: Gigabayt
GHz	: Gigahertz
JHU	: John Hopkins Üniversitesi
MLC	: Maksimum Benzerlik Sınıflandırması
MTA	: Maden Tetkik ve Arama Genel Müdürlüğü
NDVI	: Normalize edilmiş fark bitki örtüsü indeksi

RGB	: Kırmızı, yeşil, mavi
RF	: Rastgele Orman Sınıflandırması (Random Forest)
ROC	: Alıcı işlem karakteristikleri (Receiver Operating Characteristic)
SAM	: Spektral Açık Haritalayıcı (Spectral Angle Mapper)
SMA	: Spektral Karışım (Mixture) Analizi
SVM	: Destek Vektör Makinaları Sınıflandırması (Support Vector Machine)
SWIR	: Kısa dalga kızılötesi
TIR	: Termal kızılötesi
VNIR	: Yakın kızılötesi

ŞEKİLLER DİZİNİ

Şekil 1.1. a) Türkiye haritası; b) Çalışma alanının konumu (a ve b Google Earth'den alınmıştır); c) Çalışma alanının yükselti haritası	3
Şekil 1.2. Jeoloji haritası (Şenel 1997'den değiştirilmiştir.)	4
Şekil 3.1. a) Araziden günlenmiş kayaç yüzeyleri; b) yol yarmalarındaki taze kaya yüzeyleri; c) el mikroskobu ile inceleme; d) araziden alınan el örneği; e) örneklerin ince kesit ve spektoradyometre ölçümleri için kesilerek hazırlanması; f) ince kesit; g) ASD cihazı ile spektoradyometre ölçümü	11
Şekil 3.2. Sınıflandırma işlemleri iş akış şeması	14
Şekil 3.3. Çalışma sahasına ait birleştirilmiş AstSenDem veri setinin görüntüsü (RGB:VV-VNIR3-SWIR8).....	15
Şekil 3.4. Çalışma alanından toplanan eğitim örneklerinin (Model 2'ye ait), kayaç örneklerinin yerleri ve birimlerin arazi görüntüleri	17
Şekil 3.5. RF algoritması önceden verilen özelliklere bakarak her bir piksel için evet/hayır oy vererek ilerler (Ho, 1995).....	18
Şekil 3.6. SVM algoritması, verileri genellikle iki sınıfa ayıran bir hiperdüzlem çıkarır (Richards ve Jia, 2006).....	19
Şekil 3.7. ANN basit işlem düğümleri oluşturarak sınıflandırır (Haykin, 1994).....	20
Şekil 3.8. SAM görüntünün spektral benzerliğini referans spektrum ile karşılaştırır (Kruse vd., 1993).....	23
Şekil 3.9. İnce kesitlerin alttan aydınlatmalı polarizan mikroskobunda detaylı incelenmesi.....	24
Şekil 3.10. K09 nolu gabro kayacına ait ince kesitlerinin a) mikroskop; b) sınıflandırılmış görüntüleri.....	25
Şekil 4.1. Ast veri setinde MLC sınıflandırması sonucu	28
Şekil 4.2. Ast veri setinde RF uygulaması sonucu.....	29
Şekil 4.3. Ast veri setine SVM sınıflandırması sonucu	30
Şekil 4.4. Ast veri setine ANN sınıflandırması sonucu	31
Şekil 4.5. AstSen veri setine MLC uygulaması sonucu.....	32
Şekil 4.6. AstSen veri setine RF uygulaması sonucu.....	33
Şekil 4.7. AstSen veri setine SVM uygulaması sonucu.....	34
Şekil 4.8. AstSen veri setine ANN uygulaması sonucu.....	35
Şekil 4.9. AstDem veri setine MLC uygulaması sonucu	36
Şekil 4.10. AstDem veri setine RF uygulaması sonucu.....	37
Şekil 4.11. AstDem veri setine SVM uygulaması sonucu	38
Şekil 4.12. AstDem veri setine ANN uygulaması sonucu	39
Şekil 4.13. AstSenDem veri setine MLC uygulaması sonucu	40

Şekil 4.14. AstSenDem veri setine RF uygulaması sonucu.....	41
Şekil 4.15. AstSenDem veri setine SVM uygulaması sonucu	42
Şekil 4.16. AstSenDem veri setine ANN uygulaması sonucu	43
Şekil 4.17. a) K09 nolu örneğin spektral imzası ile uygulanan SAM görüntüsü; b) JHU'dan elde edilen spektral imza ile uygulanan SAM görüntüsü	44
Şekil 4.18. K09 nolu örneğe göre SMA uygulaması	45
Şekil 5.1. Litolojik birimlerin kullanıcı doğruluk değerleri grafik gösterimi	55
Şekil 5.2. Kireçtaşı ve klastiklerin AstSenDem veri setine SVM sınıflandırması sonucunun a) harita; b) arazi görüntüsü (36°51'07''K 30°20'06''D).....	56
Şekil 5.3. Kireçtaşı ve klastiklerin AstSenDem veri setindeki SVM sınıflandırması sonucunun a) harita; b) arazi görüntüsü (36°50'20''K 30°19'58''D Saklıkent).....	57
Şekil 5.4. K3 noktasındaki yamaç molozunun AstSenDem veri setindeki a) MLC; b) RF; c) SVM; d) ANN sınıflandırmasındaki sonuçları; e) arazi görüntüsü	58
Şekil 5.5. NDVI maskeleyesi yapılarak a) Ast veri setinde; b) AstSenDem veri setinde MLC sınıflandırması	59
Şekil 5.6. NDVI maskeleyesi yapılarak a) Ast veri setinde; b) AstSenDem veri setinde ANN sınıflandırması	60
Şekil 5.7. NDVI maskeleyesi yapılarak a) Ast veri setinde; b) AstSenDem veri setinde RF sınıflandırması.....	60

ÇİZELGELER DİZİNİ

Çizelge 3.1. ASTER algılayıcısının çözünürlük özellikleri.....	9
Çizelge 3.2. Sentinel-1 uydu özellikleri.....	10
Çizelge 3.3 Eğitim setlerine göre yapılmış farklı sınıflandırmaların toplam yüzde (%) doğruluk değerleri	16
Çizelge 3.4. Eğitim ve kontrol piksel sayıları.....	16
Çizelge 3.5. Değiştirilen parametreler sonucu elde edilen doğruluk değerleri.....	22
Çizelge 3.6. Karışıklık (confusion) matrisi örneği.....	26
Çizelge 3.7. Kappa değer aralıkları ve yorumlanması (Fleiss, 1971).....	27
Çizelge 4.1. Farklı modellere ait toplam doğruluk değerleri, Kappa değerleri ve sınıflandırma süreleri (saat:dakika:saniye)	46
Çizelge 4.2. Ast verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması.....	46
Çizelge 4.3. AstDem verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması.....	47
Çizelge 4.4. AstSen verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması.....	47
Çizelge 4.5. AstSenDem verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması.....	47
Çizelge 4.6. Ast verisinin her bir sınıflandırma için AUC sonuçları.....	48
Çizelge 4.7. AstDem verisinin her bir sınıflandırma için AUC sonuçları	48
Çizelge 4.8. AstSen verisinin her bir sınıflandırma için AUC sonuçları.....	48
Çizelge 4.9. AstSenDem verisinin her bir sınıflandırma için AUC sonuçları	48
Çizelge 4.10. Ast veri setinde MLC sonrası birimlerin doğru piksel sayıları.....	49
Çizelge 4.11. Ast veri setinde RF sonrası birimlerin doğru piksel sayıları	49
Çizelge 4.12. Ast veri setinde SVM sonrası birimlerin doğru piksel sayıları.....	49
Çizelge 4.13. Ast veri setinde ANN sonrası birimlerin doğru piksel sayıları.....	50
Çizelge 4.14. AstSen veri setinde MLC sonrası birimlerin doğru piksel sayıları.....	50
Çizelge 4.15. AstSen veri setinde RF sonrası birimlerin doğru piksel sayıları	50
Çizelge 4.16. AstSen veri setinde SVM sonrası birimlerin doğru piksel sayıları.....	51
Çizelge 4.17. AstSen veri setinde ANN sonrası birimlerin doğru piksel sayıları.....	51
Çizelge 4.18. AstDem veri setinde MLC sonrası birimlerin doğru piksel sayısı	51
Çizelge 4.19. AstDem veri setinde RF sonrası birimlerin doğru piksel sayısı	52
Çizelge 4.20. AstDem veri setinde SVM sonrası birimlerin doğru piksel sayısı	52
Çizelge 4.21. AstDem veri setinde ANN sonrası birimlerin doğru piksel sayısı	52

Çizelge 4.22.	AstSenDem veri setinde MLC sonrası birimlerin doğru piksel sayısı	53
Çizelge 4.23.	AstSenDem veri setinde RF sonrası birimlerin doğru piksel sayısı	53
Çizelge 4.24.	AstSenDem veri setinde SVM sonrası birimlerin doğru piksel sayısı	53
Çizelge 4.25.	AstSenDem veri setinde ANN sonrası birimlerin doğru piksel sayısı	54
Çizelge 5.1.	Litolojik birimlerdeki bitki örtüsü dağılımı	58



1. GİRİŞ

Bu çalışma Akdeniz Üniversitesi Fen Bilimleri Enstitüsü Jeoloji Mühendisliği Anabilim Dalında Doktora Tezi olarak hazırlanmıştır. Antalya körfezinin batısında yer alan Batı Toroslari içine alan yaklaşık 2500 km²'lik bir alanı kapsayan çalışma alanında litolojik birimleri ayırt etmek amacıyla, ASTER uydu verisi ve Sentinel-1 SAR verisi ile ASTER sayısal yükseklik modeli (ASTER GDEM) kullanılarak farklı sınıflandırma teknikleri uygulanmıştır.

Uzaktan algılama, fiziksel bir temas olmaksızın yeryüzündeki herhangi bir cisimden yansıyan veya yayılan enerjinin algılanması, kaydı, analizi sonucunda o cisim hakkında bilgi toplanmasına ilişkin bir bilimdir. Doğadaki her bir materyalin kendine ait farklı spektral dalga boyunda sergilediği bir spektral imzası mevcuttur. Uzaktan algılama verileri cisimlerin spektral yansıma değerlerini kaydedebilmektedir. Günümüzde uzaktan algılama verileri yer platformları, uydular, kamera yerleştirilmiş uçaklar ve insansız hava araçları tarafından sağlanmaktadır. Kameralar ve sensörler (algılayıcılar) görüntüyü; ultraviyole-morötesi (0,2-0,4 µm), kısa ve uzun dalga kızılötesi (0,7-3,0 µm) dahil termal kızıl ötesi (3,0-14,0 µm) bölgeye kadar geniş bir elektromanyetik dalga aralığında yansıyan ve yayılan enerjiyi algılayarak oluştururlar.

Teknolojinin gelişmesi ile uzaktan algılama uygulamaları birçok disiplinde önemli bir araç haline gelmiştir. Yeryüzünü görüntüleyen uydu görüntüleri ya da uçaklardan ve insansız hava araçlarından alınan hava fotoğrafı yardımı ile geniş bir alandan görüntü kaydı alınabilmekte ve elektromanyetik spektrumun insan gözünün göremediği farklı dalga boyu aralıklarında bilgi toplanabilmektedir. Diğer disiplinlerde olduğu gibi jeolojide de son zamanlarda sıklıkla yardımına ihtiyaç duyulmaktadır.

Özellikle günümüzde tüm dünyada doğal enerji kaynaklarına duyulan ihtiyaç neticesinde doğal kaynak aramacılığında zaman kazandırılması açısından uzaktan algılama teknikleri tüm dünyada hızla yaygınlaşmaktadır (Bedini, 2011; Kruse, 2012; Liu vd., 2016; Mahvash Mohammadi ve Hezarkhani, 2018; Molan vd., 2014; Rice vd., 2010; Sengupta vd., 2019). Uydu görüntüleri, uzaktan algılama yöntemleri ile kullanılarak saha çalışması öncesi bir ön çalışma sağlamasının yanında aynı zamanda bazı nedenlerden dolayı (engebeli alan gibi, yoğun bitki örtüsü gibi) ulaşamayan yerler hakkında bize bilgi sağlaması açısından da oldukça önemli bir kullanım oluşturmaktadır. Her ne kadar arazi çalışmalarına alternatif olmayıp ona yardımcı olan, potansiyel alanları belirleyerek çalışma alanını daraltan kullanışlı ve yenilikçi bir yöntem olsa da güçlü potansiyeli ile insanoğlunun fiziksel olarak ulaşımının mümkün olmadığı gezegenlerde bile litolojik haritalama için kullanılabilmektedir (Rice vd., 2010; Smith vd., 2013).

1.1. Çalışmanın Amacı

Bu çalışmanın amacı, uzaktan algılama verileri kullanılarak farklı litolojik sınıflandırma teknikleri ile Batı Antalya'ya ait litoloji haritalamasının yapılması, optik veriye SAR verisi eklenilerek sınıflandırma doğruluğunu arttırmak, farklı sınıflandırma tekniklerinin karşılaştırılmasını yapmak ve bitki örtüsü ile kaplı alanlarda uzaktan algılama yöntemlerinin sınırlarını zorlayarak litolojik ayrım yapabilmektir. Bu kapsamda ASTER ve Sentinel-1 uydu verileri kullanılarak denetimli sınıflandırma teknikleri (En Büyük Benzerlik Sınıflandırması (MLC), Rastgele Orman (RF), Destek Vektör

Makinaları (SVM), Yapay Sinir Ağları (ANN), Spektral Açık Haritalayıcı (SAM)) yardımıyla Batı Antalya'ya ait litolojik haritanın çıkartılması ve bu tekniklerin birbirleri ile karşılaştırılması amaçlanmıştır.


Çalışmanın amacı doğrultusunda farklı mekânsal ve spektral çözünürlüğe sahip optik uzaktan algılama verileri ile farklı mekânsal, spektral ve radyometrik çözünürlüğe sahip polarimetrik SAR verileri kullanılmıştır. Ayrıca bu çalışmada bitki örtüsü maskelenerek ve maskelenmeden sınıflandırma teknikleri uygulanarak bitki örtüsünün sınıflandırmaya etkisi incelenmiştir.

1.2. Çalışmanın Kapsamı

Çalışma alanı Batı Toroslar'da Antalya Körfezi batısında bulunmakta olup yaklaşık 2500 km² alanı kaplamaktadır. Çalışma alanı içerisindeki yükseklik doğuda sahil düzlüğü boyunca 0 m'den, batıda TÜBİTAK Ulusal Gözlemevi bulunan Beydağlarının zirvesi olan 2983 m'ye kadar değişim göstermektedir (Şekil 1.1). Çalışma alanında yazları sıcak ve kurak, kışları ılıman ve yağışlı olan Akdeniz iklimi etkilidir. 1930 ile 2021 yılları arasındaki yıllık ortalama sıcaklık 18.8 °C, yıllık yağış ortalaması 1060 mm olarak kaydedilmiştir (MGM, 2022). Çalışma alanında gözlenen ana bitki örtüsü ormanlık alanlarda ağırlık olarak kızılçam ağacı ve maki denilen ve ormanın yanması sonucu oluşan küçük ağaç ya da bodur çalılık alanlardan oluşmaktadır. Ayrıca bölgede yer yer sedir ve karaçam ağacı da görülmektedir (OGM, 2022). Çalışma alanının %8,9'luk bir kısmı yoğun bitki örtüsü ile kaplıdır.

Çalışma alanı Beydağları otoktonunu, Antalya naplarını, Likya naplarını ve Yeşilbarak napını kapsamaktadır.

Beydağları otoktonu (Günay vd., 1982), Jura-Kretase yaşlı neritik kireçtaşları, Paleosen yaşlı kumtaşı, kumlu-killi kireçtaşları, Üst Lütesiyen-Priaboniyen yaşlı kalkarenit düzeyli kumtaşı, kilaşı, Alt Miyosen yaşlı alglı kireçtaşları, kumtaşı, kilaşı ve silttaşı ile konglomera ve kumtaşları içermektedir (Şenel, 1997).




Şekil 1.1. a) Türkiye haritası; **b)** Çalışma alanının konumu (a ve b Google Earth'den alınmıştır); **c)** Çalışma alanının yükselti haritası

Antalya napları (Lefevre, 1967), alttan üste doğru Çataltepe napı, Alakırçay napı, Tahtalıdağ napı ve Tekirova ofiyolit napından oluşmaktadır. Çataltepe napı yapısal olarak Antalya naplarının en alt birimini oluşturur (Şenel, 1997). Çataltepe napı; marn, radyolarit, çört, şeyl, kalsitürbidit, radyolarit ve bloklu fliş içermektedir (Poisson, 1977). Alakırçay napı yapısal olarak Çataltepe napı üzerinde, Tahtalıdağ napı altında bulunur ve Kumluca ve Alakırçay birimleri olmak üzere iki yapısal birimden oluşur (Şenel, 1997). Alakırçay napı; mizzialı kireçtaşları, marn, bitkili kumtaşı, şeyl, spilitleşmiş bazalt, radyolarit, çört, halobialı mikrit, halobialı kireçtaşları, kumtaşı, bazik volkanit ve tabakalı çört içermektedir (Kalafatçıoğlu, 1973). Tahtalıdağ napı yapısal olarak Alakırçay napı üzerinde bulunur (Şenel, 1997). Genel olarak Kambriyen-Üst Kretase yaşlı platform tipi kayalar kapsmaktadır. Tahtalıdağ napı; dolomit, yumrulu kireçtaşları, kumtaşı, şeyl, kumlu dolomit, kıltaşı, silttaşı, kuvarsitik kumtaşları, neritik kireçtaşı içermektedir (Şenel

vd., 1981). Yapısal konumu tartışmalı olan Tekirova ofiyolit napı; ofiyolitli melanj olan Kırkdirek formasyonu (Şenel vd., 1981) ve okyanusal kabuk kayaçlarından oluşan Tekirova ofiyolitini (Juteau, 1975; Reuber, 1982) kapsar. Tekirova ofiyolitleri Geç Kretase dönemde Neotetis'in güney kolunun kapanması sırasındaki dalma batma zonunda oluşmuştur (Bağcı vd., 2006). Tekirova ofiyoliti serpantin, lertzolitik harzburjit, masif harzburjit, bantlı harzburjit, dünit, kromlu dünit, verlit, piroksenit, plajiyoklazlı verlit, tabakalı gabro, izotropik gabro, plajiyogranit, diyabaz dayk karmaşığı ve izole diyabaz dayklarından oluşur (Güneş vd., 2021; Reuber, 1982). Bağcı ve Parlak, (2009) çalışmasında bu bölgenin kümülatik verlit, lertzolit, klinopiroksenit, kümülatik gabro, masif (izotropik) gabro, diyabaz dayk, pegmatitik gabro ve plajiyogranitlerden oluştuğunu savunmuşlardır.

Yeşilbarak napı (Şenel vd., 1987), Beydağları otoktonu ile Likya napları arasında yanal yönlerde süreklilik gösterir. Yeşilbarak napı kumtaşı, şeyl, kireçtaşı ve kıltaşından oluşmaktadır. Likya napları farklı ortam koşullarında oluşmasına rağmen Gülbahar napı ile temsil edilir. Gülbahar napı radyolarit ve çört ara düzeyli çörtlü mikritlerden oluşmaktadır. Bölgede Kuvaterner; Antalya traverten, yamaç molozu ve alüvyonlarla temsil edilmektedir (Şekil 1.2).



Şekil 1.2. Jeoloji haritası (Şenel 1997'den değiştirilmiştir.)

2. KAYNAK TARAMASI

Jeolojik uzaktan algılama kullanılarak görüntü teknikleri üzerine literatürde birçok çalışma bulunmaktadır. Bunlardan bazıları sedimanter (Kavak, 2005; Olivares vd., 2009; Öztan ve Süzen, 2011; Kodikara vd., 2012; Hassler vd., 2013; Rajendran ve Nasir, 2014) bazıları ofiyolitik (Khan ve Mahmood, 2008; Tangestani vd., 2011; Pournamdari ve Hashim, 2014; Pournamdari vd., 2014; Eslami vd., 2015; Rajendran ve Nasir, 2015; Bahrambeygi ve Moeinzadeh, 2017) olmak üzere litolojik haritalama amaçlı olarak yapılmıştır. Bazıları da sadece mineral haritalama üzerine (Bedini, 2011; Cui vd., 2015; Kruse, 2012; Liu vd., 2011; Mars ve Rowan, 2010; Molan vd., 2014; Pour vd., 2013; Rowan vd., 2005; Sabins, 1999; Wang vd., 2017) yapılmıştır. Bazıları ise yapısal ve çizgisel amaçlı (Akgün vd., 2021; Ni vd., 2017; Tagnon vd., 2020; Teikeu vd., 2016) yapılmıştır. Bu çalışmalarda bant oranlama, dekorelasyon gemesi (decorrelation stretch), Minimum Gürültü Oranlaması (Minimum Noise Fraction-MNF), Temel Bileşenler Analizi (Principal Component Analysis-PCA) gibi teknikler kullanılmıştır. Son yıllarda uzaktan algılama çalışmalarında makine öğrenme (machine learning) algoritmaları kullanılmaya başlanmıştır. Uzaktan algılama çalışmalarında birçok farklı disiplinde yaygın bir şekilde kullanılmakta olan makine öğrenme algoritmaları son yıllarda jeoloji alanında da kullanılmaya başlamıştır.

Huang vd. (2002) yapmış oldukları çalışma destek vektör makinalarının teorik gelişimine ve uydu görüntülerinden arazi örtüsü sınıflandırmalarının elde edilmesindeki eğitim hızının, doğruluğunun ve güvenilirliğinin değerlendirilmesine giriş niteliğinde bir çalışmadır. Araştırmacılar, SVM'yi çok boyutlu veri kümelerinin sınıflandırılmasında kullanılan mevcut en iyi makine öğrenme algoritmaları olarak nitelendirirken MLC, ANN ve karar verme ağacı sınıflayıcıları ile karşılaştırmışlardır.

Chen vd. (2007) çalışmasında veri setleri oluşturarak SFF (spectral feature fitting) ve SAM uygulamalarını yapmışlardır. SAM uygulaması multispektral ve hiperspektral verilerle iyi performans sağladığını kanıtlamışlardır.

Huang vd. (2007) optik verilerle (Landsat) radar verilerini (Radarsat) entegre ederek sınıflandırma potansiyelini göstermişlerdir. Sadece Landsat verisinin kullanılması ile elde edilen sınıflandırmaya kıyasla daha anlamlı bir düzelme olduğu ve hata oranında %16'lık bir azalma olduğu tespit edilmiştir.

Grebby vd. (2011), çalışmasında Kıbrıs'ta bulunan Troodos ofiyolitlerinin bitki örtüsü kaplı bir alanda litolojik haritalamada havadan alınan (airborne) multispektral görüntünün etkinliğinin LiDAR'dan elde edilen sayısal arazi modeli (DTM) verisinin entegrasyonu ile artırıldığını göstermektedir. Bu çalışmada sınıflandırma için MNF ve PCA teknikleri kullanılmıştır. Çalışma sonuçları multispektral görüntüye eklenen verinin doğruluk değerlerini artırdığını göstermektedir.

Mountrakis vd. (2011) çalışmalarında SVM algoritmasını başka çalışmacılara ait yüzün üzerindeki çalışmalarını derleyerek uydu görüntüleri üzerinde uzaktan algılama tekniği olarak kullanılabileceğini kanıtlamıştır.

Yu vd. (2012) kuzeybatı Hindistan'da SVM kullanarak çalışma alanına otomatik litolojik sınıflandırma uygulamıştır. Çalışmasında ASTER, ASTER'den elde ettiği DEM

ve havadan manyetizma (aeromagnetic) verilerini ve bu üç veriden türetilen (principal components, independent components kullanılarak) 33 veri seti ile birlikte toplamda 47 veri seti üzerinde SVM uygulanarak en yüksek sınıflandırma doğruluğu test edilmiştir. MLC'nin SVM ile karşılaştırılmasında SVM'nin litolojik haritalamada daha yüksek doğruluk sağladığını kanıtlamıştır. Çalışmasında SVM'nin mevcut litolojiler hakkında bazı bilgilerin olduğu alanlar için harita oluşturulmasında yardımcı olabileceğini önermiştir.

Othman ve Gloaguen (2014) çalışmasında KD Irak'ta bulunan Mawat Ofiyolit Kompleksinin ASTER verisini kullanarak SVM ile litolojik haritalamasını yapmıştır.

Cracknell ve Reading (2014) uzaktan algılama verisi kullanarak jeolojik haritalama üzerine yaptıkları çalışmalarında Naive Bayes, en yakın komşu (k-Nearest Neighbors), rastgele orman, destek vektör makinaları ve yapay sinir ağları olmak üzere beş farklı makine öğrenme algoritmaları kullanarak bunların karşılaştırılmasını yapmışlardır. Bu çalışmada RF'nin diğer makine öğrenme algoritmalarına göre daha doğru olduğunu tespit etmişlerdir.

Harvey ve Fotopoulos (2016) çalışmasında dört denetimli makine öğrenme algoritması (Naive Bayes, k-NN, RF ve SVM) kullanarak kayaç tiplerinin doğru bir şekilde tanımlanması için performanslarını değerlendirmişlerdir. Bu çalışma rastgele ormanın en iyi yaklaşım olduğunu göstermektedir.

Lary vd. (2016) çalışmasında jeolojide makine öğrenme algoritmaları kullanılarak yapılan bu çalışmaların geniş bir özetini yaparak jeolojide kullanımının önemli ve gerekli olduğuna vurgu yapmıştır. Jeoloji ve uzaktan algılama problemlerinin üstesinden gelmek için makine öğrenme algoritmalarının etkin bir yöntem olacağını göstermişlerdir.

Momeni vd. (2016), İngiltere'deki Nottingham çevresindeki arazi örtüsünün haritalanmasında mekânsal, spektral ve sınıflandırmaların etkisi. WorldView-2 görüntüsü değişen spektral ve mekânsal özelliklere sahip 12 görüntü kümesi sağlamıştır ve bunlar üç farklı sınıflandırma (maksimum olasılık (ML), destek vektör makinesi (SVM) ve nesne tabanlı görüntü analizi (OBIA)) ile toplamda 36 harita elde edilmiştir. Sınıflandırma doğruluğu bağımsız olarak değerlendirilmiş ve hangi sınıflandırmaların önemli ölçüde farklı olduğunu belirlemek için tüm eşleştirilmiş çıktılar (toplam 630 çift) arasında McNemar testleri yapılmış. Toplam doğruluk (overall accuracy) 30 m uzamsal çözünürlüklü 4-bantlı görüntü için ML sınıflandırmasında %35, ve 2 m uzamsal çözünürlüklü 8-bantlı görüntü için OBIA sınıflandırmasında %91 arasında değişmektedir.

Weilin vd. (2016) radar ve optik uzaktan algılama verisinin litolojik sınıflandırmada uygulamasını kapsayan çalışmasında MLC kullanmışlardır. Çalışmada ilk önce ASTER verisine daha sonra ASTER ve RadarSAT-2 verisini birleştirerek litolojik amaçlı sınıflandırma yapmışlardır. Sonuçlar sınıflandırma doğruluğunun artırılması için radar ve optik verinin birlikte kullanılarak sınıflandırma yapılmasını göstermektedir.

Bahrambeygi ve Moeinzadeh (2017) İran'ın güney doğusundaki Mesina bölgesinde ofiyolitik alanda yaptıkları çalışmada ofiyolitik alanlarda haritalama

yapmanın zorluklarına değinmiştir. Bu çalışmada Hyperion verisi kullanarak SVM ve ANN tekniklerini kullanmışlar ve sırasıyla %52 ve %65 genel doğruluk değerlerini bulmuşlardır. Bu çalışma sonucuna göre harmanlanmış karmaşık birimlerin ayrılmasında ANN yöntemi kabul edilebilir bir doğruluk oranına sahiptir.

Othman ve Gloaguen (2017) çalışmalarında ASTER verisi kullanarak Kuzeydoğu Irak'taki Zagros Sütur Zonunda makine öğrenme algoritmalarından MLC ve SVM, ayrıca RF, bant oranlama, PCA uygulayarak litolojik haritalama yapmışlardır. Çalışma bölgesinde bulunan serpantin, konglomera, kireçtaşı, kireçli konglomera, bazik lavlarla ara katkılı tüfit, metamorfize olmuş kireçtaşı, yeşil şist birimlerini başarılı bir şekilde haritalamıştır.

Hassan ve Sadek (2017) Korbai-Gerf kompleksinde (Mısır) yaptıkları çalışmada bant oranlama, PCA (Temel Bileşen Analizi), ICA (Bağımsız Bileşen Analizi) ve SVM teknikleri kullanarak litolojik sınıflandırma yapmışlardır. Çalışmada ASTER ile Landsat-8 verilerinin ve PCA ile ICA sonuç verilerinin birleştirilmesi ile elde edilen veri setinin en yüksek doğruluk derecesine sahip olduğu görülmüştür. Sınıflandırma tekniklerinden SAM, SID (Spectral Information Divergence), SVM kullanmışlardır ve bu çalışmada en yüksek doğruluk derecesine SVM sınıflandırmasında ulaşılmıştır.

Radford vd. (2018) çalışmasında Heazlawood bölgesinde (Batı Tazmania) havadan polarimetrik veriler (TopSAR) ve jeofiziksel verileri kullanarak manuel ve otomatik litolojik sınıflandırma yöntemlerini uygulamışlardır. Otomatik sınıflandırma için RF yönteminin uygulandığı bu çalışmada Radar verisi kullanılmış veri ile Radar verisi kullanılmamış veri arasında karşılaştırma yapmışlardır. Bu çalışma, uzak ve erişilemeyen bölgeler için bitki örtüsünün yoğun olduğu bölgelerde jeolojik haritalamada makine öğrenme uygulamalarının doğruluğunu ve SAR verisinin katkısını vurgulamaktadır.

Xie vd. (2018) çalışması Naive Bayes, SVM, ANN, RF ve Degrade Ağacı Artırma (Gradient Tree Boosting) olmak üzere beş tipik makine öğrenme yönteminin değerlendirmesidir. Litoloji tipini sınıflandıracak en iyi modeli belirlemek için her model için en iyi parametre setini elde etmekte hiper-parametre optimizasyon yöntemini kullanmışlardır. Sonuç olarak her ne kadar tüm modeller kumtaşı sınıfını ayırt etmede zorluk çekse de Degrade Ağacı Artırma ve RF yöntemlerinin sınıflandırma doğruluğu diğer sınıflandırmalara kıyasla yüksek çıkmıştır.

Bachri vd. (2019), Souk Arbaa Sahel bölgesinde (batı Anti-Atlas, Fas) yaptıkları çalışmada ALOS/PALSAR verilerinin jeomorfometrik özneliklerinden elde ettikleri DEM verisi ile Landsat 8 OLI verisinin birleştirip kullanarak SVM tekniğinin performansını değerlendirmeyi ve bölgeye ait litolojiyi haritalamayı amaçlamışlardır. Toplam sınıflandırma doğruluk değerlendirmesinden %85 sonuç almışlardır.

Erith vd. (2020), Ekvator'daki Amotape Tahuin metamorfik kompleksinde RF sınıflandırması ile ASTER, Landsat 8, Alos Palsar (HH, HV) ve Sentinel-1 (VV, VH) verilerini kullanarak farklı veri setleri oluşturup sınıflandırma yapmıştır. Verileri birbirleri ile birleştirerek sadece Landsat, Landsat ve Alos Palsar, Landsat ve ASTER, Landsat ve Sentinel, Landsat+ASTER+Alos Palsar, Landsat+Alos Palsar+Sentinel veri setlerini oluşturmuşlardır. Bu veri setlerine RF yöntemi ile sınıflandırma yaparak doğruluk

sonuçlarını sedimanter, magmatik ve metamorfik kayalardaki doğruluk değerlerini birbirleri ile karşılaştırmışlardır. Landsat 8 sonuçlarından farklı olarak, Alos Palsar verilerinin eklenmesi ile oluşturdukları veri setinin doğruluk değerinin yüksek olması sonucu; bitki örtüsü altında hem toprak nemi hem de toprak bilgilerinin alınmasına izin verir, bu da yalnızca Landsat 8 görüntülerinin kullanılmasına kıyasla sınıflandırma kapasitesini artırır yorumunu yapmışlardır.

Maepa vd. (2021), Ontario bölgesindeki Swayze kuşağında (Kanada) yaptıkları çalışmada ANN ve SVM yöntemlerini kullanarak altın olasılık haritalaması yapmışlardır. K-fold çapraz doğrulama yaklaşımını kullanarak eğitim ve test örnekleri oluşturmuşlardır. Girdi katmanı olarak da litoloji haritası, fay haritası, jeokimyasal anomali haritası, aeromanyetik veriler, elektromanyetik veriler kullanılmıştır. Çalışma sonunda ROC eğrisinin altındaki ortalama alan ANN için %91 ve %94, SVM için %91 ve %87 doğruluk elde etmişlerdir.

Shayeganpour vd. (2021), çalışmalarında SVM, Naive Bayes (NB), k-en yakın komşu (k-NN) ve RF sınıflandırmalarının performanslarını değerlendirmiş ve karşılaştırmıştır. Bu çalışma kapsamında bir metamorfik kompleksde (GB İran) ASTER, Landsat-8, Sentinel-1 ve Sentinel-2A verileri kullanarak nesne tabanlı görüntü analizinin makine öğrenme teknikleriyle birleştirilmişler ve litolojik haritalama yapmışlardır. Nesne tabanlı görüntü analizini ekledikten sonra RF, SVM, k-NN ve NB sınıflandırmalarındaki doğruluk değişimleri sırasıyla; %90'dan %98'e, %81'den %97'ye, %52'den %75'e ve %40'tan %64'e yükseldiğini gözlemlemişlerdir.

3. MATERYAL VE METOT

3.1. Materyal

Çalışma alanına ait jeolojik haritalar (MTA tarafından hazırlanan 1:100 000 ölçekli Türkiye Jeoloji Haritaları L10 ve L11 paftaları), bölgeye ait dijitalleştirilmiş jeoloji ve litoloji haritaları, uydu görüntüleri ve polarimetrik SAR verileri elde edilmiştir. Sentinel-1 görüntüsü ESA'nın sitesinden çalışma alanını kapsayacak şekilde en uygun olan görüntüler seçilerek temin edilmiştir. Çalışma alanı ve çalışma metodu ile ilgili kitap, makale, tez, bildiri, rapor gibi kaynaklar derlenmiş, çalışma alanı ve yakın çevresine ait yapılmış jeoloji haritaları L10 ve L11 paftaları incelenmiştir. Bu tez kapsamında kullanılan bilgisayar, Akdeniz Üniversitesi Bilimsel Araştırma Projeleri kapsamında temin edilmiştir. Bilgisayar işlemci hızı XEON 3.80 GHz ve RAM 16.0 GB özelliklere sahiptir. Çalışmada kullanılan materyaller ASTER optik verisi (GDEM, VNIR, SWIR, TIR) ve Sentinel-1 SAR (HH-HV, VV-VH) verisidir. Ayrıca John Hopkins Üniversitesi Spektral Kütüphanesini içeren NASA'ya ait "speclib.jpl.nasa.gov" adresinden SAM uygulaması için gabro kayacına ait en uygun spektral imza temin edilmiştir.

ASTER (The Advanced Spaceborne Thermal Emission and Reflection Radiometer) NASA tarafından TERRA uzay aracı üzerine yerleştirilmiş multispektral görüntüleri kaydeden gelişmiş bir algılayıcıdır. ASTER algılayıcısı üç farklı algılayıcıdan oluşmaktadır: Görünür ve Yakın-Kızılötesi (VNIR) 15 m'lik mekânsal çözünürlüğe sahip 3 bant (Bant 1, 2 ve 3N) ve bir bant stereo görüş için geri bakış teleskopu (3B); Kısa Dalga Kızılötesi (SWIR) 30 m'lik mekânsal çözünürlüğe sahip 6 bant ve Termal Kızılötesi (TIR) 90 m'lik mekânsal çözünürlüğe sahip 5 bantta sahiptir. VNIR ve SWIR görüntüleri 8 bit, TIR görüntüleri 12 bit radyometrik çözünürlüğe sahiptir. Zamansal çözünürlüğü 16 gün olan uydunun tarama genişliği 60 km'dir (Çizelge 3.1). ASTER verileri 60x60 km alana sahip görüntüler şeklinde olmaktadır. Bu çalışmada 29.12.2005 tarihine ait level-3 ve kısa adı AST3A01 olan uzun adı AST3A1 0506070857120512290765 olan ASTER uydu verisi kullanılmıştır.

Çizelge 3.1. ASTER algılayıcısının çözünürlük özellikleri

	BantNo	Spektral çözünürlük (μm)	Mekânsal çözünürlük	Radyometrik çözünürlük
VNIR	1	0,52-0,60	15 m	8 bit
	2	0,63-0,69		
	3N-B	0,78-0,86		
SWIR	4	1,60-1,70	30 m	8 bit
	5	2,145-2,185		
	6	2,185-2,225		
	7	2,235-2,285		
	8	2,295-2,365		
	9	2,360-2,430		
TIR	10	8,125-8,475	90 m	12 bit
	11	8,475-8,825		
	12	8,925-9,275		
	13	10,25-10,95		
	14	10,95-11,65		

Sentinel-1, Copernicus programı öncülüğünde ESA'nın geliştirdiği, tüm hava koşullarında, gece ve gündüz boyunca görüntü sağlayan C banda sahip gelişmiş bir radar aleti taşıyan uydudur. C-Bantlı SAR cihazı tek kutuplu (HH veya VV) ve çift kutuplu (HH+HV veya VV+VH) polarizasyon değerlerini kaydetmektedir. Sentinel-1 dört farklı modda 12 gün aralıklarla görüntü temin edebilmektedir. Bunlar; 80 km tarama genişliği olan 5x5 m mekânsal çözünürlüklü StripMap (SM), 250 km tarama genişliği olan 5x20 m mekânsal çözünürlüklü interferometrik geniş tarama (Interferometric Wide Swath - IW), 400 km tarama genişliği olan 25x100 mekânsal çözünürlüklü ekstra geniş tarama (Extra-Wide Swath - EW), 100 km tarama genişliği olan 5x20 m mekânsal çözünürlüklü dalga (Wave - WV)'dir (Attema vd., 2007) (Çizelge 3.2). Bu çalışmada çalışma alanını içine alan en uygun veri ESA'nın kendi sitesinden (scihub.copernicus.eu) taranarak HH-HV polarimetre verisi için 20.05.2016 tarihli GRD ürünü EW verisi olan dosya adı S1A_EW_GRDM_1SDH_20160520T035843_20160520T035943_011337_011344_A1 F7 olan veri kullanılmıştır. VV-VH için 02.06.2017 tarihli IW verisi olan dosya adı S1B_IW_SLC__1SDV_20170521T035807_20170521T035835_005691_009F87_94C2 olan veri kullanılmıştır.

Çizelge 3.2. Sentinel-1 uydu özellikleri

Sensör tipi	Spektral çözünürlük ve polarimetri			Mekansal çözünürlük (m)	Radyometrik çözünürlük	Şerit genişliği (km)
SM	C-Bant	Frqz: 5.405 GHz	HH-HV VV-VH	5x5	10 bit	80
IWS				5x20		250
EWS				25x100		400
Wave				5x20		100

Çalışma sahasına araziye farklı mevsimlerde görme amacı ile farklı aylarda arazi çalışmaları düzenlenmiştir. Araziden hem günlenmiş kayaç yüzeylerinden (Şekil 3.1a) hem yol yarmalarındaki taze kaya yüzeylerinden (Şekil 3.1b) gerektiği yerlerde el mikroskobu ile inceleme yapılarak (Şekil 3.1c) numaralı ve koordinatlı 19 adet el örneği (Şekil 3.1d) alınmıştır. Araziye ilk düzenlenen çalışmadan alınan el örnekleri Akdeniz Üniversitesi Jeoloji Mühendisliği Kesithane Laboratuvarında ince kesit ve spektoradyometre ölçümleri için kesilerek (Şekil 3.1e) ayrı ayrı hazırlanıp paketlenmiştir. İnce kesitler uzman bir kişiye hizmet alımı olarak yaptırılmıştır (Şekil 3.1f). Spektoradyometre ölçümleri MTA Uzaktan Algılama ve CBS Laboratuvarlarına ait ASD (Analytical Spectral Devices) cihazında (Şekil 3.1g) yapılmıştır.



Şekil 3.1. a) Araziden günlenmiş kayaç yüzeyleri; b) yol yarmalarındaki taze kaya yüzeyleri; c) el mikroskobu ile inceleme; d) araziden alınan el örneği; e) örneklerin ince kesit ve spektrometre ölçümleri için kesilerek hazırlanması; f) ince kesit; g) ASD cihazı ile spektrometre ölçümü

3.2. Metot

Bu çalışmada; ön çalışma, arazi çalışması, laboratuvar çalışması ve ofis çalışması kısımlarına ayrılabilir. Ön çalışma, gerekli olan materyaller edinilerek çalışma sahası hakkında bilgi elde etmeyi kapsar. Arazi çalışması; sınıflandırma öncesi, sınıflandırma sırası ve sınıflandırma sonrasında gerçekleşmiştir. Laboratuvar çalışması; araziden alınan örneklerin kesilmesi, ince kesitlerin incelenmesi, spektrometre ölçümleri çalışmalarını kapsamaktadır. Ofis çalışmaları kısmında da elde edilen uzaktan algılama verilerine ön işlem uygulamaları, verilerin veri seti haline getirilmesi, eğitim ve kontrol setlerinin hazırlanması, sınıflandırma çalışmalarını içeren tüm adımları içermektedir.

Uzaktan algılama ile analiz edilen sayısal görüntüler, düzenli ve düzensiz bazı hatalar içerir. Bu hatalar görüntü ön işleme aşamasında giderilir. Ön işlemler, esas verilerin ve bilgilerin doğru olarak ortaya çıkarılması için yapılması gerekli olan hazırlıkları içerir. Bunlar radyometrik ve geometrik düzeltmeler olarak isimlendirilirler. Bu çalışmada ASTER uydu görüntülerinde radyometrik ve geometrik olarak hata olmadığından herhangi bir düzeltme yapılma ihtiyacı olmamıştır. Sentinel-1 uydu verileri ESA'nın kendi sitesinden ham veri olarak elde edilmiştir. Farklı zamanlara ait görüntüler içerisinde en uygun olanı seçilmiştir. Veriler çift polarizasyonlu HH+HV ve VV+VH polarizasyon değerleri IW ve EW olmak üzere iki farklı şekilde elde edilmiş, geometrik ve radyometrik düzeltmeleri yapılmıştır. Polarimetrik SAR verileri geniş bir alanı kapladıkları için kullanılan bu iki görüntü SNAP programında çalışma alanını kapsayacak görüntüden ilgili alan çıkarılmıştır.

14 adet çok-bantlı ASTER görüntüsü farklı mekânsal, spektral ve radyometrik çözünürlüğe sahiptir. Görüntü işleme ve analizlerinin yapılabilmesi için bu bantlar tek bir (Ast) dosya haline dönüştürülmüştür. ASTER görüntüsü ile ASTER'den elde edilen sayısal yükseklik modeli (GDEM) verisi birleştirilerek 15 bantlı ASTER+DEM veri seti (AstDem) oluşturulmuştur. ASTER görüntüsü ile 4 bantlı HH+HV ve VV+VH polarizasyon verileri birleştirilerek 18 bantlı ASTER+Sentinel veri seti (AstSen) oluşturulmuştur. Son olarak tüm verilerin birleşimi ile 19 bantlı ASTER+Sentinel+DEM veri seti (AstSenDem) olmak üzere ayrı ayrı dört farklı görüntü veri seti elde edilmiştir (Şekil 3.2).

Farklı uydu görüntüleri farklı mekânsal çözünürlüklere sahip oldukları için en uygun mekânsal çözünürlük denenerek tespit edilmiş ve veri setleri mekânsal çözünürlüğü 15 m olacak şekilde birleştirilmiştir. Sınıflandırma sırasında sınıflandırmayı etkilememesi için deniz alanları maskelenmiş ve 0-1 arasına normalize edilerek sabit veri setleri oluşturulmuştur. Bu çalışmada bitki örtüsü göz ardı edilmeden sınıflandırmaya dahil edilerek kullanılmıştır.


Sınıflandırma yöntemleri; görüntüdeki her bir piksel için spektral parlaklık değerlerini analiz ederek benzer imzaları aynı sınıflandırdığı piksellere atama tekniğidir. Sınıflandırma işleminden sonra harita ve görüntü üzerindeki bu sınıflar her biri farklı renk ve sembollerle tanımlanmış tek bir görüntü elde edilir. Litolojik sınıflandırmada her renk veya sembol bir litolojiyi temsil etmektedir.

Sınıflandırma teknikleri Eğitimli Sınıflandırma (Supervised Classification) ve Eğitimsiz Sınıflandırma (Unsupervised Classification) olmak üzere ikiye ayrılır.

Eğitimsiz Sınıflandırmada programa görüntüde kaç tane sınıf olduğu girilir program spektral verilere göre istatistiki yöntemlerle sınıflandırmayı yapar. Eğitimli Sınıflandırma tekniğinde ise kullanıcı programa görüntüde hangi sınıfa neresinin ait olduğunu gösterir ve program öğrenme algoritmalarına dayalı yöntemleri kullanarak sınıflandırmayı yapar. Makine öğrenme algoritmalarına dayalı yöntemler; Maksimum Benzerlik Haritası (Maximum Likelihood Classification), Paralel Çizgiler (Paralelpiped), Minimum Mesafe (Minimum Distance), Destek Vektör Makinaları (Support Vector Machine), Rastgele Orman (Random Forest), Yapay Sinir Ağları (ANN-Artificial Neural Network)'dır.


Bu çalışmada eğitimli sınıflandırma tekniklerinden Maksimum Benzerlik Sınıflandırması (MLC), Destek Vektör Makinaları (SVM), Rastgele Orman (RF) ve Yapay Sinir Ağları (ANN) yöntemleri uygulanmıştır. Bunların dışında ayrıca Kemer bölgesini içine alan bölge pilot bölge olarak alınarak bu bölgede SAM ve karışım (Mixture) Analizi uygulanmıştır.





Şekil 3.2. Sınıflandırma işlemleri iş akış şeması

Eğitimli sınıflandırma teknikleri öncesinde herhangi bir RGB bant kombinasyonu görüntüsünde eğitim seti ve kontrol seti alanları belirlenerek makine öğrenme algoritmasının eğitilmesi sağlanır. Eğitim ve kontrol setlerin oluşturulması sınıflandırmanın yönlendirilmesi olduğu için bu aşama oldukça önemlidir. Bu çalışmada litolojik birimlerin ayrımının kolay yapılabilirdiği AstSenDem verisinin RGB görüntüsü üzerinde, litoloji haritası ve arazi gözlemleri referans alınarak eğitim seti ve bağımsız olarak kontrol seti hazırlanmıştır (Şekil 3.3). Çalışmada ilk önce eğitim setleri rastgele toplanmıştır. Chen ve Stow (2002) eğitim amacıyla alınan nokta ve alan örneklerinin karşılaştırılmasını yaptığı çalışmasından yararlanılarak %80 eğitim örnekleri ve %20 kontrol örnekleri olacak şekilde küçük ve sık aralıklarla poligonlar alınmıştır (Çizelge 3.3).



Şekil 3.3. Çalışma sahasına ait birleştirilmiş AstSenDem veri setinin görüntüsü (RGB:VV-VNIR3-SWIR8)

Çizelge 3.3 Eğitim setlerine göre yapılmış farklı sınıflandırmaların toplam yüzde (%) doğruluk değerleri

	Rastgele alınan eğitim ve kontrol örneklerine göre doğruluk değerleri (%)			%80 eğitim ve %20 kontrol örneklerine göre doğruluk değerleri (%)		
	MLC	SVM	RF	MLC	SVM	RF
Ast	81,72	84,64	81,99	86,42	88,74	84,26
AstDem	84,08	85,45	88,48	89,23	93,26	89,38
AstSen	84,43	85,63	84,80	87,41	91,05	87,31
AstSenDem	85,35	87,16	89,41	90,26	95,72	93,61


Tüm jeolojik birimlerin ayrı bir sınıf olarak alınması halinde sınıflandırma için büyük bir kargaşa oluşturacağından litolojik birimler birleştirilerek gruplandırma yapılmıştır. Bu durum çalışma alanının büyük bir alanı kaplamasından kaynaklıdır. Çalışma alanında birçok farklı litolojik birim bulunduğundan (Şekil 1.2) dolayı arazi çalışmaları ve jeoloji haritaları temel alınarak litolojik olarak benzer olanlar yedi birime ayrılmış, ayrıca çalışma sahası içerisinde yer alan su kütleleri de ayrı bir sınıf olarak alınarak toplam sekiz (8) sınıf dikkate alınmıştır. Farklı yaşlarda olan killi kireçtaşı, kumlu kireçtaşı gibi litolojiler “kireçtaşı”; tufa ve traverten “traverten”; serpantin, serpantinleşmiş gabro gibi litolojiler “peridotit”; volkanik ve magmatik kayaların karmaşığı “melanj”; radyolarit ve çört “çört”; çakıltası, kumtaşı, çamurtaşı gibi litolojiler “klastikler”; ve ayrıca “alüvyon” ve “su” birimleri de olacak şekilde 8 farklı sınıf oluşturulmuştur (Şekil 3.4). Bu litolojik birimlerden oluşan jeoloji haritası (Şenel, 1997) ve arazi gözlemleri temel alınarak birbirinden bağımsız 3 eğitim örnek alanları ve bunlardan bağımsız 3 kontrol örnek alanları alınmıştır (Çizelge 3.4). Bu örneklerden elde edilen toplam doğruluk değeri, Kappa değeri ve işlemin süresinin sonuçları Çizelge 4.1’de gösterilmiştir.

Çizelge 3.4. Eğitim ve kontrol piksel sayıları

	Model 1		Model 2		Model 3	
Sınıflar	eğitim	kontrol	eğitim	kontrol	eğitim	kontrol
Alüvyon	1100	315	918	230	861	230
Traverten	1116	285	857	211	827	211
Peridotit	2066	682	1056	297	1056	297
Kireçtaşı	8020	1982	1562	393	2566	601
Melanj	2308	645	1051	311	1051	311
Klastikler	2489	715	1006	375	1571	375
Çört	961	302	671	177	634	177
Su	220	72	136	39	485	149

Bitki örtüsünü belirgin hale getirmek, ön plana çıkarmak için normalize edilmiş bitki fark indeksi (NDVI) denilen bir bant oranlama kullanılmaktadır. Bitkiler kızılötesi (NIR) bantta yüksek, kırmızı bantta düşük yansıma gösterdiğinden NIR-R değerinin NIR+R değerine oranı bize NDVI değerini verir. Bu da ASTER için $(b3-b2)/(b3+b2)$

bantlarının oranlaması demektir. Biz bu indeks değerini tam tersi olarak bitki örtüsünü maskelemek için de kullanabiliriz.



Şekil 3.4. Çalışma alanından toplanan eğitim örneklerinin (Model 2'ye ait), kayaç örneklerinin yerleri ve birimlerin arazi görüntüleri

3.2.1. Maksimum Benzerlik Haritası

Maksimum Benzerlik Haritası (Maximum Likelihood Classification-MLC), çalışma alanındaki yansıma değerlerinin dağılımına uygulanan Bayesian olasılık teorisine dayalı istatistiksel fonksiyonlara bağlı bir sınıflama yöntemidir. Yöntem, bir pikselin o sınıfa ait olma olasılığını değerlendirir ve en yüksek üye olma olasılığına göre atar (Richards ve Jia, 2006). Bu yöntemin en büyük avantajı hızlı olmasıdır. Tüm veri setlerine önceden hazırlanan eğitim setlerle ENVI 5.0 programında MLC uygulanmıştır. Analiz

sonucu ENVI 5.0 Programında aynı kontrol seti kullanılarak analiz sonrası doğruluk değerlendirmesi yapılmıştır.

ENVI, görüntüdeki her piksel için (3.1) bağıntısındaki hesaplamayı yaparak en yüksek olasılık sınıfını belirler (Richards, 1999):

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (3.1)$$

i = sınıf

x = n -boyut veri (n kadar bant sayısı)

$p(\omega_i)$ = ω_i sınıfının görüntüdeki olma olasılığı ve tüm sınıflar için aynı olduğu varsayılır


$|\Sigma_i|$ = ω_i sınıfındaki verinin kovaryans matrisinin determinanı

Σ_i^{-1} = ters matrisi

m_i = ortalama vektör

3.2.2. Rastgele Orman

Rastgele Orman (Random Forest-RF), karar ağacı sınıflandırma yöntemlerinden biridir. Bu yöntemde her bir ağaç modeli girdi vektörünü sınıflandırmak için ağaçta bulunan en baskın sınıfa bir oy verir (Ho, 1995). Her bir piksel tüm ağaç tahminlerinde en fazla oy alan sınıfa atanmasıyla sınıflandırılır (Şekil 3.5). Bir karar ağacının oluşturulmasında dallanma kriterlerinin belirlenmesi gerekmektedir. RF için dallanma sayısı programa girilirken sayı ne kadar büyük olursa sınıflandırmanın doğruluğu o kadar iyi olabilmekte ya da fazla rakam doğruluğu bozabilmektedir (Breiman, 2001).




Şekil 3.5. RF algoritması önceden verilen özelliklere bakarak her bir piksel için evet/hayır oy vererek ilerler (Ho, 1995)

Tüm veri setlerine uygulanan eğitim seti ENVI 5.1 programında EnMAP-Box için uygun format olan roi'den image formatına dönüştürülerek EnMAP-Box_vm.2.2.0 programında RF uygulanmıştır. Karar ağacı sayısı sırasıyla 10, 100, 1000, 10000 denenmiştir. 1000'den az kullanılan ağaç sayısında doğruluk düşük olduğundan, 1000'den fazla ağaç sayısında 1000 ağaç sayısı ile aynı sınıflandırmayı verdiği için dolayı 1000 karar ağaçlı sınıflandırma sonucu kullanılmıştır. Programın kullanacağı parametreleri önceden programa optimizasyon edilerek belirlenmiştir. Analiz sonucu ENVI 5.0 Programında aynı kontrol seti kullanılarak analiz sonrası doğruluk değerlendirmesi yapılmıştır.

3.2.3. Destek Vektör Makinaları

Destek Vektör Makinaları (Support Vector Machine-SVM), ilk olarak Cortes ve Vapnik (1995) tarafından düşünülen bu teknik uzaktan algılama görüntü sınıflandırmasına kazandırılmıştır. SVM, sadece ayrılmış hiperdüzlem (hyperplane, destek piksel vektörlerine verilen isim) yakınındaki piksellere bağlı yaklaşımdır ve düzleme göre sınıflandırma yapar (Vapnik, 1999). Güvenilir bir sınıflandırma yapmak için hiperdüzlemin nerede olması gerektiğini tanımlayan, ayıran, hiperdüzlem yakınındaki pikselleri bulan yöntemdir (Richards ve Jia 2006) (Şekil 3.6). Bu yöntem birçok yönteme göre hızlı çalışmasına karşın yine birçok yönteme göre tutarlı sonuçlar vermesi açısından çoğu çalışma tarafından tercih edilmektedir (Ada ve San, 2018; Aktas ve San, 2019; Ge vd., 2018; Gualtieri ve Crompt, 1998; Hassan ve Sadek, 2017; J. Anthony Gualtieri; R. F. Crompt, 1999; Othman ve Gloaguen, 2014; San, 2014; Zhang vd., 2009).




Şekil 3.6. SVM algoritması, verileri genellikle iki sınıfa ayıran bir hiperdüzlem çıkarır (Richards ve Jia, 2006)

Tüm veri setlerine aynı eğitim setiyle ENVI 5.0 programında SVM uygulanmıştır. Uygulamada parametreler; radyal basis fonksiyon kernel tipinde olacak şekilde, penalty parametresi 100, gamma sayısı Ast veri seti için 0,071 (Othman ve Gloaguen, 2017), AstDem için 0,067, AstSen için 0.056, AstSenDem için 0,053 alınmıştır.

3.2.4. Yapay Sinir Ağları

Yapay Sinir Ağları (Artificial Neural Network-ANN), nöron adı verilen birkaç basit işlem düğümünden oluşan bir hesaplama aracıdır (Haykin, 1994). ANN, insanların görevleri öğrenen, kalıpları sınıflandıran ve problemleri çözen biyolojik sinir ağı modelini taklit eden bir yapay zeka tekniğidir (Negnevitsky, 2005) (Şekil 3.7). Örüntü tanıma yaygın olarak kullanılan ANN sınıflandırıcısı, görüntü verilerinin sınıflandırılmasında da son zamanlarda kullanılmaya başlamıştır (He vd., 2015; Ge vd., 2018).

Tüm veri setlerine aynı eğitim örnekleri kullanılarak ENVI 5.0 programında ANN sınıflandırması yapılmıştır. Uygulamada kullanılan parametreler deneme yanılma ile belirlenmiştir. Tek bir parametre değiştirilip diğerleri sabit tutularak elde edilen sonuçlara göre en uygun parametreler belirlenmiştir. Denemeler sonucu en yüksek sonucu veren değerler birbirleri ile uyumu da göz önüne alınarak kullanılmıştır.



Şekil 3.7. ANN basit işlem düğümleri oluşturarak sınıflandırır (Haykin, 1994)

Teta Değeri (TTC-Training Threshold Contribution), düğümün aktivasyon seviyesine göre iç ağırlığın katkısını belirler ve 0-1 arası bir değer girilir. Düğümlerin iç ağırlıklarının ayarlanması daha iyi sınıflandırmalara yol açabilir, ancak çok fazla ağırlık da zayıf genellemelere yol açabilir (Richards, 1999).

Eğitim Hızı (TR-Training Rate), ağırlık ayarının büyüklüğünü belirler ve 0-1 arası bir değer girilir. Daha yüksek bir hız, antrenmanı hızlandıracak, fakat aynı zamanda salınımlar veya antrenman sonucunun yakınlaşmaması riskini de artıracaktır (Richards, 1999).

Eğitim Momentumu (TM-Training Momentum), 0-1 arası bir değer girilir. Sıfıra yakın bir momentum oranı girmek, salınımsız daha yüksek bir eğitim hızı ayarlanmasına olanak sağlar. Daha yüksek bir momentum hızı, daha düşük bir momentum hızından daha büyük adımlarla çalışır (Richards, 1999).

Eğitim RMS Çıkış Kriteri (TRMSEC-Training RMS Exit Criteria), eğitimin durması gereken RMS hata değeri girilir. Eğitim sırasında hedef noktalarda gösterilen RMS hatası girilen değer altına düşerse, iterasyon sayısı karşılanmamış olsa bile eğitim durur (Richards, 1999).

Gizli Katman Sayısı (NHL-Number of Hidden Layers), kullanılacak olan gizli katmanların sayısıdır. Doğrusal bir sınıflandırma için 0 değeri girilir. Doğrusal olmayan sınıflandırmalar için gizli katman sayısı 1 veya daha büyük bir değere ayarlanarak gerçekleştirilir (Richards, 1999).

Eğitim İterasyon Sayısı (NTI- Number of Training Iterations), eğitimde kullanılacak olan dönme sayısıdır (Richards, 1999).

Bu sonuçlara göre (Çizelge 3.5) parametreler;


- ✓ Teta Değeri (TTC-Training Threshold Contribution) 0.3
- ✓ Eğitim Oranı (TR-Training Rate) 0.05
- ✓ Eğitim Momentumu (TM-Training Momentum) 0.5
- ✓ Eğitim RMS Çıkış Kriteri (TRMSEC-Training RMS Exit Criteria) 0.1
- ✓ Gizli Katman Sayısı (NHL-Number of Hidden Layers) 1
- ✓ Eğitim İterasyon Sayısı (NTI- Number of Training Iterations) 1000 alınmıştır.

Çizelge 3.5. Değiştirilen parametreler sonucu elde edilen doğruluk değerleri

TTC	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	
Doğruluk değeri	76,64	85,98	86,28	81,21	79,29	81,60	85,19	86,87	82,69	
TR	0,001	0,05	0,1	0,2	0,3	0,5				
Doğruluk değeri	87,85	88,49	86,42	82,69	43,97	32,71				
TM	0,9	0,7	0,5	0,3	0,1	0,05				
Doğruluk değeri	82,69	87,31	87,11	86,13	84,70	84,75				
TRMSEC	0,05	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
Doğruluk değeri	82,69	82,69	82,69	82,69	87,85	88,83	78,11	54,25	69,50	63,01
NHL0	0	1	2	3						
Doğruluk değeri	78,41	82,69	53,32	20,22						
NTI	100	500	1000	3000	5000	8000	10000			
Doğruluk değeri	83,92	87,11	82,69	88,10	64,88	88,05	84,85			

3.2.5. Spektral Açı Haritalaması

Cisimler elektromanyetik spektrumun farklı dalga boyu aralığında farklı yansıma veya emilim özelliğine sahiptirler. Her mineralin kendine özgü spektral yansıması vardır ve bu da spektral imzasıdır. Spektral Açı Haritalaması (Spectral Angle Mapping-SAM), görüntünün spektral benzerliğini referans spektrumlarla karşılaştırıp eşleştirerek kullanılan bir yöntemdir (Kruse vd., 1993). Laboratuvardan ya da araziden alınan spektrumlar referans spektrum olarak kullanılabilir. İki spektrum arasındaki benzerlik, spektrumların dağılımının vektörel gösterimindeki açı (α) hesaplanarak belirlenir (Şekil 3.8). Açılar yeterince farklı olduğundan spektrumlar birbirinden ayırt edilebilir (Richards ve Jia, 2006)



Şekil 3.8. SAM görüntünün spektral benzerliğini referans spektrum ile karşılaştırır (Kruse vd., 1993)

Bu uygulama yapılmadan önce bütün çalışma sahasını temsil eden Kemer bölgesi pilot bölge tespit edilerek arazi çalışması yapılmıştır. Kemer bölgesinde bulunan ofiyolitlerin içerisinde bulunan peridotitlerin genel kayaç ayrımı için yapılması düşünülmüştür. Araziden alınan örnekler ince kesit ve spektoradyometre ölçümleri için hazırlanmıştır. Spektoradyometre ölçümleri MTA Uzaktan Algılama ve CBS Laboratuvarlarında yapılmıştır. İnce kesitler incelenerek el örnekleri de referans alınıp kayaç adlandırmaları yapılmıştır. Laboratuvarda alınan reflektans değerleri EK-2’de verilmiştir. Spektral imzalar ASTER verisine uygun olacak şekilde hazırlanmıştır. Ön hazırlık aşamasından geçen spektral imzalar aracılığı ile ASTER veri setine ENVI 5.0 programında SAM uygulanmıştır.

John Hopkins Üniversitesi Spektral Kütüphanesinden elde edilen gabro kayacına ait spektral imzalar ASTER için ön hazırlıktan geçirilerek Kemer bölgesine SAM uygulanmıştır.

3.2.6. Spektral Karışım Analizi

Spektral Karışım Analizi (Spectral Mixture Analysis-SMA), kayaçları oluşturan minerallerin spektral imzalarını kullanarak kayacın spektral imzasını bulmaya dayalı bir tekniktir. Pilot bölgede bulunan peridotitleri sınıflandırma amacıyla SMA tekniği uygulanmıştır. Ultrabazik kayaç türüne giren peridotitler mineral oranlarına göre dünit, harzburgit ve lertzolit olarak isimlendirilmektedir. Az miktarda kuvars, feldspat ve mika çeşitlerinin yanı sıra, özellikle olivin, piroksen ve amfibol mineralleri bazik ve ultrabazik kayaçların isimlendirilmesinde çok önemli rol oynarlar. Magmatik kayaç sınıflandırmalarında da temel mineral bileşimi ve kayanın dokusu ön planda tutularak sınıflandırma yapılır. Magma içinde bulunan elementler soğuma sıcaklıklarına göre magmadan kristallenerek mineralleri oluştururlar. İki temel silikat gurubu mineralleri vardır; koyu renkli silikatlar (Fe-Mg çok) ve açık renkli silikatlar (K, Na, Ca çok). Olivin, piroksen, amfibol ve biyotit en yaygın koyu renkli minerallerdir. Kuvars, muskovit, feldspat gurubu mineraller en yaygın açık renkli minerallerdir. Magmatik kayaçlar önce oluşum yerlerine göre derinlik, volkanik ve damar kayacı olarak ayrılır. Mineral içeriğine göre felsik (granitik), ortaç (andezitik), mafik (bazaltik), ultramafik (peridotit) olarak

gruplandırılır. Daha sonra kayacın içindeki minerallerin birbirine göre oranları belirlenerek kayacın ismi belirlenir.


Bu çalışmada el örneklerinden yapılan ince kesitler Akdeniz Üniversitesi Jeoloji Mühendisliği Bölümündeki Genel Jeoloji Laboratuvarındaki Olympos marka CX31 model alttan aydınlatmalı Polarizan Mikroskobunda detaylı incelemesi yapılmıştır (Şekil 3.9) (EK-1). Yine aynı bölümdeki Optik Mineraloji Laboratuvarında bulunan Nikon marka eclipse 50i model alttan aydınlatmalı Polarizan Mikroskobunda görüntüleri alınmıştır.



Şekil 3.9. İnce kesitlerin alttan aydınlatmalı polarizan mikroskobunda detaylı incelenmesi

Olympos marka CX31 model alttan aydınlatmalı Polarizan Mikroskobunda detaylı incelemeler sırasında gabra olduğu tespit edilen K09 nolu ince kesit üzerinde çalışma yapılmasına karar verilmiştir. İnce kesitte kayacın plajiyoklaz, piroksen ve opak minerallerden oluştuğu tespit edilmiştir. Piroksen mineralleri polarizan ışık altında çift nikoldeyken sönme gösterirler. Ortopiroksenler düz sönme, klinopiroksenler eğik sönme gösterir. Klinopiroksenler yüksek çift kırınım özelliğe sahiptir. Bu durum bu mineralin farklı açılardayken farklı renk yansımaları göstermesi demektir. K09 nolu örnekte bulunan piroksenler klinopirosendir. Döner tabladaki açı bilgilerinden yararlanılarak ince kesitin 0°'de tek nikol, 0°'de çift nikol, 45°'de çift nikol, 90°'de çift nikol RGB görüntülerinin fotoğrafları bilgisayara bağlı Nikon marka eclipse 50i model alttan aydınlatmalı polarizan mikroskobunda çekilmiştir (Şekil 3.10). Her bir görüntü döndürülen yönün tersine döndürülen açı kadar görüntü işleme programında (Photoshop) döndürme işlemi yapılmıştır. Örneğin saat yönünde 45° döndürülerek çekilen görüntü saat yönünün tersine 45° döndürülüp tüm görüntüler üst üste çakıştırılmıştır. Görüntülerin sadece çakışan alanları kalacak şekilde diğer alanları kesilmiştir. Bütün görüntüler en son hali ile üst üste bindirilerek ENVI programında birleştirilmiştir. Her bir görüntünün 3

bantlı RGB görüntüsü olduğundan toplamda 4 adet görüntünün birleştirilmesi ile sonuçta 12 bantlı veri elde edilmiştir. Bu veri setine SVM tekniği ile piroksen, plajiyoklaz ve opak minerallerin sınıflandırması yapılarak veri setindeki oranları tespit edilmiştir.



Şekil 3.10. K09 nolu gabro kayacına ait ince kesitlerinin **a)** mikroskop; **b)** sınıflandırılmış görüntüleri

Sınıflandırma sonucunda plajiyoklaz 3.343.854 piksel, piroksen 3.021.534 piksel, opak mineral ise 355.764 piksel olarak sınıflandırılmıştır. Yapılan hesaplamalar sonucunda %50 plajiyoklaz, %45 piroksen ve %5 opak mineral olduğu tespit edilmiştir.

Minerallerin spektral eğrileri NASA'ya ait “speclib.jpl.nasa.gov” adresinden ücretsiz olarak temin edilmiştir. Plajiyoklaz minerali “albit” ve “anortit” minerallerinin karışımı ile olduğundan bu minerallerin spektral imzaları bulunarak kullanılmıştır. Mafik bir kayaç olduğundan plajiyoklazın %75'i anortit %25'i albit minerali olacak şekilde kullanılmıştır. İnce kesitlerin detaylı incelemesi sırasında uralitleşme olduğu tespit edildiğinden opak minerallerin spektral eğrileri “uralit” olarak alınmıştır. Spektral değerleri yüzde oranları ile çarpılıp çıkan değerler toplanarak son hali kayacın spektral değeri olarak kabul edilmiştir. Bulunan bu değerler ASTER için ön hazırlıktan geçirilerek ENVI 5.1 programında Kemer bölgesine SAM uygulaması olarak uygulanmıştır.

3.2.7. Sonuçların doğruluk analizi

Sınıflandırma sonrası bulunan görüntüler birbirleri ile ve var olan litoloji haritası ile karşılaştırılmıştır. Görsel açıdan bütünlük ve tutarlık arz eden sonuç tespit edilmeye çalışılmıştır. Sınıflandırma sonrası sınıflandırmaların sonuçları ayrı ayrı kml dosyası haline getirilerek Google Earth programı kullanılarak arazide denetimi yapılmıştır.

Görsel sonuçların yanı sıra tüm görüntülerin MLC, RF, SVM ve ANN sonuçlarına sınıflandırma sonrası (post-classification) aynı kontrol seti kullanılarak ENVI 5.1 programında doğruluk analizi için karışıklık matrisi (confusion matrix) yaptırılmıştır (Çizelge 3.6). Tüm sınıflandırma sonuçlarının programda doğruluk yüzdeleri (Eşitlik 3.2) (accuracy assesment) ve Kappa değeri (Eşitlik 3.3) (Kappa value) hesaplatılmıştır. Çıkan sonuçlar sayısal olarak karşılaştırılmıştır.

Çizelge 3.6. Karışıklık (confusion) matrisi örneği

	Doğru (D)	Yanlış (Y)
Pozitif (P)	DP	YP
Negatif (N)	DN	YN

Doğru Pozitifler (DP); bunlar her bir piksel için o pikselin tahmin ettiğimiz değerinin 1 olduğu ve pikselin gerçek değerinin 1 (yani sınıflandırılmış) örneklerdir.

Doğru Negatifler (DN); bunlar her bir piksel için o pikselin tahmin ettiğimiz değerinin 0 olduğu ve pikselin gerçek değeri 0 (yani o sınıfa ait değil) olan örneklerdir.

Yanlış Pozitifler (YP); bunlar her bir piksel için o pikselin tahmin ettiğimiz değerinin 1 olduğu fakat pikselin gerçek değeri 0 olan örneklerdir.

Yanlış Negatif (YN); bunlar her bir piksel için o pikselin tahmin ettiğimiz değerinin 0 olduğu fakat pikselin gerçek değeri 1 olan örneklerdir.

$$\text{Doğruluk (Accuracy)} = \frac{DP + DN}{DP + YP + DN + YN} \quad (3.2)$$

Kappa katsayısı, iki değerleyici arasındaki uyumun derecesini yada güvenilirliğini ölçmek için yapılan istatistiki bir yöntemdir (Cohen, 1960). Kappa katsayısı (K) hesaplanırken iki farklı olasılık hesaplanır. Bunlar iki değerlendirici için gözlenen uyumun toplam oranı olan $Pr(a)$ ve bu uyumun şansa bağlı olasılığı olan $Pr(e)$ 'dir.

$$K = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (3.3)$$

(3.3) bağıntısı sonucunda elde edilen değerin yorumu basittir. Çıkan sonuç 0'a yaklaştıkça uyumsuzluğu, 1'e yaklaştıkça tam uyumu belirtir (Cohen, 1960). İlk aşamada iki değerleyici arasındaki uyum için kullanılmaya başlasa da Fleiss (1971) tarafından ikiden fazla değerleyicinin uyumunu yorumlamak için genel bir tablo oluşturulmuştur (Çizelge 3.7).

Çizelge 3.7. Kappa değer aralıkları ve yorumlanması (Fleiss, 1971)

K değeri	Yorum
<0,00	Şansa bağlı uyum olması
0,01-0,20	Önemsiz düzeyde uyum olması
0,21-0,40	Zayıf düzeyde uyum olması
0,41-0,60	Orta düzeyde uyum olması
0,61-0,80	İyi düzeyde uyum olması
0,81-1,00	Çok iyi düzeyde uyum olması

Ayrıca her bir sınıflandırma sonucunun sınıflandırılmış 7 birimi her birim ayrı olacak şekilde kontrol örnekleri ile ROC eğrisi çizdirilerek eğri altında kalan alan (Area Under Curve, AUC) hesabı yaptırılmıştır. Sınıflandırıcının tüm olası değerler üzerindeki performansını değerlendirmek için kullanılan bir grafikdir. Doğru pozitif değerlerin hassasiyet oranına (Eşitlik 3.4) karşı yanlış pozitif değerlerin oranı (Eşitlik 3.5) ile çizilerek oluşturulur. AUC yorumlanırken 1'e yakınlığı ve 0'a yakınlığına göre yorumlanır. 1'e yakınlığı o modelin tahmin etmedeki başarısını gösterir.


$$\text{Hassasiyet (Precision)} = \frac{DP}{DP + YP} \quad (3.4)$$

$$\text{Yanlış Pozitif Değerler} = \frac{YP}{DN + YP} \quad (3.5)$$

4. BULGULAR

4.1. Ast Veri Setinde MLC Sınıflandırması


İlk veri setimiz olan ve sadece ASTER görüntüsünün VNIR, SWIR ve TIR değerlerini içeren 14 bantlı veriye MLC yöntemi uygulanmıştır (Şekil 4.1). MLC yapıldıktan sonra kontrol set kullanılarak doğruluk analizi yapılmıştır. Toplam doğruluk değeri %86,42 ve Kappa değeri 0,8409 bulunmuştur. MLC sınıflandırması hızlı bir sınıflandırma yöntemidir. Bunun sonucu olarak bulunan tematik harita bize ön bilgi vermesi açısından kullanışlı olabilir ancak yeterli değildir.



Şekil 4.1. Ast veri setinde MLC sınıflandırması sonucu

4.2. Ast Veri Setinde RF Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye RF sınıflandırması uygulanmıştır (Şekil 4.2). Analiz sonucu doğruluk değerlendirmesi yapılmıştır. Toplam doğruluk değeri %84,26 ve Kappa değeri 0,8155 bulunmuştur. Ast verisinde uygulanan RF sınıflandırması sonucu bulunan sonuçlar da hatalı sınıflandırmalar göze çarpmaktadır.



Şekil 4.2. Ast veri setinde RF uygulaması sonucu

4.3. Ast Veri Setinde SVM Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye SVM sınıflandırması uygulanmıştır (Şekil 4.3). Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %88,74 ve Kappa değeri 0,8680 bulunmuştur. Hem görsel olarak hem doğruluk değeri olarak SVM tekniği oldukça iyidir. MLC tekniğine göre biraz daha uzun sürmesine rağmen SVM tekniği hem büyük hem karmaşık alanlar için uygulanabilecek bir teknik olduğunu kanıtlamıştır. Fakat alan büyük ve karmaşık olduğu için ASTER’de uygulanan MLC kadar olamasa da SVM içinde de yanlış sınıflandırma alanları oluşmuştur.



Şekil 4.3. Ast veri setine SVM sınıflandırması sonucu

4.4. Ast Veri Setinde ANN Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye ANN sınıflandırması uygulanmıştır (Şekil 4.4). ANN sınıflandırmasında birçok parametre bulunmaktadır. Bunlar teker teker değiştirilip denenerek en yüksek doğruluk değerlerini veren parametreler kullanılmıştır. Optimum parametre sınıflandırmaya göre değişiklik göstermektedir ve optimum parametreyi bulmak zaman almaktadır. Fakat parametre tespitinden sonra sınıflandırma işlemi SVM'ye göre hızlı olmaktadır. Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %88,88 ve Kappa değeri 0,8697 bulunmuştur. Hem görsel olarak tutarlı bir harita hem de doğruluk değeri olarak en yüksek değere sahip sınıflandırma tekniği olmuştur.



Şekil 4.4. Ast veri setine ANN sınıflandırması sonucu

4.5. AstSen Veri Setinde MLC Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye Sentinel-1 uydusundan elde edilen VV-VH-HH-HV polarimetri verileri eklenerek üretilen 18 bantlı AstSen verisine MLC uygulanmıştır (Şekil 4.5). Sınıflandırma sonrası doğruluk analizi uygulaması doğruluk analizi yapılmıştır. Toplam doğruluk değeri %87,41 ve Kappa değeri 0,8952 bulunmuştur. Ast veri seti kullanılarak yapılan MLC sınıflandırmasından doğruluk değerinin 0,9838 arttığı görülmüştür.



Şekil 4.5. AstSen veri setine MLC uygulaması sonucu

4.6. AstSen Veri Setinde RF Sınıflandırması


18 bantlı AstSen veri setine RF sınıflandırması uygulanmıştır (Şekil 4.6). RF uygulamasından sonra doğruluk analizi yapılmıştır. Toplam doğruluk değeri %87,31 ve Kappa değeri 0,8513 bulunmuştur. Sadece Ast veri seti kullanılarak uygulanan RF yönteminden AstSen veri setine uygulanan RF yöntemi arasında doğruluk değerinin %3,05 oranında arttığı görülmüştür.



Şekil 4.6. AstSen veri setine RF uygulaması sonucu

4.7. AstSen Veri Setinde SVM Sınıflandırması


18 Bantlı AstSen verisine SVM sınıflandırması uygulanmıştır (Şekil 4.7). Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %91,05 ve Kappa değeri 0,8952 bulunmuştur. Ast veri seti kullanılarak uygulanan SVM yönteminden AstSen veri setine uygulanan SVM yöntemi arasında doğruluk değerinin %2,31 oranında arttığı görülmüştür.



Şekil 4.7. AstSen veri setine SVM uygulaması sonucu

4.8. AstSen Veri Setine ANN Sınıflandırması


18 bantlı AstSen verisine ENVI 5.1 Programı yardımıyla aynı eğitim set kullanılarak ANN sınıflandırması uygulanmıştır (Şekil 4.8). Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %91,39 ve Kappa değeri 0,8991 bulunmuştur. Ast veri seti kullanılarak uygulanan ANN yönteminden AstSen veri setine uygulanan ANN yöntemi arasında doğruluk değerinin %2,51 oranında arttığı görülmüştür.



Şekil 4.8. AstSen veri setine ANN uygulaması sonucu

4.9. AstDem Veri Setine MLC Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye ASTER'den elde edilen DEM verisi eklenerek üretilen 15 bantlı AstDem veri setine MLC uygulanmıştır (Şekil 4.9). MLC uygulamasından sonra sınıflandırma sonrası toplam doğruluk analizi uygulaması ile doğruluk analizi yapılmıştır. Doğruluk değeri %89,23 ve Kappa değeri 0,8735 bulunmuştur. Sadece Ast verisi kullanılarak yapılan MLC sınıflandırmasından doğruluk değerinin %2,81 arttığı görülmüştür.



Şekil 4.9. AstDem veri setine MLC uygulaması sonucu

4.10. AstDem Veri Setine RF Sınıflandırması


15 bantlı AstDem veri setine RF sınıflandırması uygulanmıştır (Şekil 4.10). RF uygulamasından sonra sınıflandırma sonrası doğruluk analizi uygulaması ile doğruluk analizi yapılmıştır. Toplam doğruluk değeri %89,38 ve Kappa değeri 0,8753 bulunmuştur. Sadece Ast veri seti kullanılarak uygulanan RF yönteminden AstDem veri setine uygulanan RF yöntemi arasında doğruluk değerinin %5,12 oranında arttığı görülmüştür.



Şekil 4.10. AstDem veri setine RF uygulaması sonucu

4.11. AstDem Veri Setine SVM Sınıflandırması


ASTER görüntüsüne DEM verisi eklenerek üretilen 15 bantlı AstDem veri setine SVM sınıflandırması uygulanmıştır (Şekil 4.11). Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %93,26 ve Kappa değeri 0,921 bulunmuştur. Doğruluk değerinin sadece Ast verisi kullanılarak uygulanan SVM yöntemine göre %4,53 oranında arttığı görülmüştür.



Şekil 4.11. AstDem veri setine SVM uygulaması sonucu

4.12. AstDem Veri Setine ANN Sınıflandırması


15 bantlı AstDem verisine ANN sınıflandırması uygulanmıştır (Şekil 4.12). Sınıflandırma sonrası doğruluk analizi sonucu toplam doğruluk değeri %88,93 ve Kappa değeri 0,8702 bulunmuştur. Doğruluk değerinin sadece Ast verisi kullanılarak uygulanan ANN yöntemine göre %0,05 oranında arttığı görülmüştür.



Şekil 4.12. AstDem veri setine ANN uygulaması sonucu

4.13. AstSenDem Veri Setine MLC Sınıflandırması


ASTER görüntüsünü içeren 14 bantlı veriye ASTER'den elde edilen DEM verisi ve Sentinel-1'den elde edilen VV-VH-HH-HV polarimetri verileri eklenerek üretilen 19 bantlı AstSenDem verisine MLC uygulanmıştır (Şekil 4.13). MLC uygulamasından sonra sınıflandırma sonrası doğruluk analizi yapılmıştır. Toplam doğruluk değeri %90,26 ve Kappa değeri 0,8855 bulunmuştur. Sadece Ast verisi kullanılarak yapılan MLC sınıflandırmasından doğruluk değerinin %3,84, AstSen verisinden %2,85 ve AstDem verisinden %1,03 arttığı görülmüştür.



Şekil 4.13. AstSenDem veri setine MLC uygulaması sonucu

4.14. AstSenDem Veri Setine RF Sınıflandırması


Tüm verilerin birleştirilmesi ile elde edilen 19 bantlı AstSenDem verisine RF sınıflandırması uygulanmıştır (Şekil 4.14). RF uygulamasından sonra sınıflandırma sonrası doğruluk analizi uygulaması ile doğruluk analizi yapılmıştır. Toplam doğruluk değeri %93,61 ve Kappa değeri 0,9253 bulunmuştur. Sadece Ast veri seti kullanılarak uygulanan RF yönteminden %9,35 oranında, AstSen veri setinden %6,3 oranında ve AstDem veri setinden %4,23 oranında doğruluk değerinin arttığı görülmüştür. Sonuçlara bakılınca RF sınıflandırmasında sadece Ast verisi kullanılarak yapılan sınıflandırmaya oranla AstSenDem verisinin doğruluğundaki bu artış bize RF sınıflandırmasının birleştirilmiş verilerde kullanılmasının daha uygun olduğunu göstermektedir.



Şekil 4.14. AstSenDem veri setine RF uygulaması sonucu

4.15. AstSenDem Veri Setine SVM Sınıflandırması


AstSenDem veri setine SVM uygulanmış ve uygulamadan sonra sınıflandırma sonrası doğruluk analizi uygulaması ile doğruluk analizi yapılmıştır (Şekil 4.15). Toplam doğruluk değeri %95,72 ve Kappa değeri 0,9499 bulunmuştur. Sadece Ast verisi kullanılarak yapılan SVM sınıflandırmasından doğruluk değerinin %6,99, AstSen verisinden %4,67 ve AstDem verisinden %2,46 arttığı görülmüştür. Ayrıca SVM uygulamasının MLC uygulamasından doğruluk değerinin %5,46 fazla olduğu görülmüştür.



Şekil 4.15. AstSenDem veri setine SVM uygulaması sonucu

4.16. AstSenDem Veri Setine ANN Sınıflandırması


AstSenDem veri setine ANN uygulanmıştır (Şekil 4.16). Uygulanan sınıflandırma sonrası doğruluk analizi uygulaması ile doğruluk analizi yapılmıştır. Toplam doğruluk değeri %94,88 ve Kappa değeri 0,9401 bulunmuştur. Doğruluk değerleri SVM sınıflandırmasına yakın çıkmasına rağmen görsel olarak ANN sınıflandırması daha tutarlı bir sonuç vermiştir.



Şekil 4.16. AstSenDem veri setine ANN uygulaması sonucu

4.17. Kemer Bölgesinde SAM Uygulaması


Araziden alınan el örneklerinden MTA Uzaktan Algılama ve CBS Laboratuvarında reflektans değerleri alınmıştır. İnce kesitlerin detaylı incelemesi sonucu gabro olduğu tespit edilen K09 nolu örneğin spektral imzası kullanılarak pilot bölge olarak seçilen Kemer bölgesinde bulut ve deniz maskelenerek SAM uygulaması yapılmıştır. Bunun dışında John Hopkins Spektral Kütüphanesinden gabro kayacına ait spektral imza ile yapılan SAM sonuçları karşılaştırılmıştır (Şekil 4.17).



Şekil 4.17. a) K09 nolu örneğin spektral imzası ile uygulanan SAM görüntüsü; **b)** JHU'dan elde edilen spektral imza ile uygulanan SAM görüntüsü

4.18. Kemer Bölgesinde SMA Uygulaması

Araziden alınan kayaç örneklerinden yapılan ince kesitler detaylı olarak incelenmesi sonucu gabro olduğuna karar verilen K09 nolu örnek kullanılmaya karar verilmiştir. Örneğin mikroskop görüntüleri birleştirilerek birleştirilen veriden SVM sınıflandırması ile mineral oranları tespit edilmiştir. Reflektans değerleri temin edilen minerallerin mineral oranlarına göre çarpılıp toplanan ve son değeri tespit edilen değerler ile Kemer bölgesine bulut ve deniz maskelenerek SAM uygulanmıştır (Şekil 4.18).



Şekil 4.18. K09 nolu örneğe göre SMA uygulaması

4.19. Doğruluk Analizi Sonuçları

Sınıflandırma sonrasında her bir sınıflandırma için doğruluk değerlendirmesi yapılmıştır. Bu değerlendirmede sınıflandırmanın toplam doğruluk değeri, Kappa değeri ve süreleri (Çizelge 4.1) ve bunların dışında her bir litolojik birim için üretici doğruluk (Producer Accuracy) ve kullanıcı doğruluk (User Accuracy) değerleri elde edilmiştir (Çizelge 4.2-4.5). Bu değerler birbirleriyle karşılaştırılmıştır.

Çizelge 4.1. Farklı modellere ait toplam doğruluk değerleri, Kappa değerleri ve sınıflandırma süreleri (saat:dakika:saniye)

	Model-1			Model-2			Model-3		
	Eğitim	Kontrol		Eğitim	Kontrol		Eğitim	Kontrol	
Alüvyon	1100	315		918	230		861	230	
Traverten	1116	285		857	211		827	211	
Peridotit	2066	682		1056	297		1056	297	
Kireçtaşı	8020	1982		1562	393		2566	601	
Melanj	2308	645		1051	311		1051	311	
Klastikler	2489	715		1006	375		1571	375	
Çört	961	302		671	177		634	177	
MLC	toplam	Kappa	süre	toplam	Kappa	süre	toplam	Kappa	süre
Ast	86,5079	0,8128	00:01:51	86,4240	0,8409	00:01:56	90,7699	0,8908	00:01:56
AstDem	85,8743	0,8188	00:01:58	89,2277	0,8735	00:02:12	92,3011	0,9088	00:01:57
AstSen	84,8739	0,8041	00:02:31	87,4078	0,8522	00:02:06	90,8975	0,8923	00:02:22
AstSenDem	86,7547	0,8281	00:02:30	90,2607	0,8855	00:02:27	93,5347	0,9234	00:01:20
RF	toplam	Kappa	süre	toplam	Kappa	süre	toplam	Kappa	süre
Ast	74,1497	0,6655	00:43:11	84,2597	0,8155	00:44:15	85,6231	0,8296	00:44:11
AstDem	77,8511	0,7116	00:40:38	89,3753	0,8753	00:40:04	95,0659	0,9416	00:39:23
AstSen	81,9728	0,7674	00:44:33	87,3094	0,8513	00:43:59	86,0910	0,8355	00:42:15
AstSenDem	86,1345	0,8182	00:43:18	93,6055	0,9253	00:39:59	96,5547	0,9593	00:38:23
SVM	toplam	Kappa	süre	toplam	Kappa	süre	toplam	Kappa	süre
Ast	82,6731	0,7774	01:53:05	88,7359	0,8680	00:53:24	90,1319	0,8833	01:09:46
AstDem	90,0160	0,8721	01:35:21	93,2612	0,9210	00:39:42	93,7048	0,9254	00:54:33
AstSen	86,6146	0,8271	02:17:40	91,0477	0,8952	00:56:31	91,6631	0,9016	01:10:10
AstSenDem	90,6563	0,8816	02:04:04	95,7206	0,9499	00:40:54	96,1718	0,9548	00:49:09
ANN	toplam	Kappa	süre	toplam	Kappa	süre	toplam	Kappa	süre
Ast	84,5738	0,7984	00:14:02	88,8834	0,8697	00:07:51	90,8124	0,8913	00:11:53
AstDem	86,7347	0,8311	00:14:59	88,9326	0,8702	00:08:22	94,4279	0,9341	00:11:34
AstSen	87,3149	0,8385	00:15:12	91,3920	0,8991	00:08:02	92,0459	0,9062	00:10:10
AstSenDem	87,2949	0,8368	00:15:30	94,8844	0,9401	00:08:18	97,3628	0,9689	00:12:01

Çizelge 4.2. Ast verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması

Litolojik Birimler	MLC		RF		SVM		ANN	
	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.
Alüvyon	93,48	95,98	72,61	96,53	90,87	100,00	90,00	99,04
Traverten	96,68	80,31	95,73	71,38	99,53	75,81	99,53	74,73
Peridotit	92,26	87,82	80,13	84,10	87,88	87,58	83,16	93,92
Kireçtaşı	86,26	83,91	93,89	89,35	95,42	85,42	94,15	86,85
Melanj	82,64	82,90	85,21	84,94	85,21	88,93	94,86	84,29
Klastikler	72,80	83,23	74,67	81,87	74,67	90,91	77,87	91,82
Çört	88,70	96,32	89,83	84,57	93,22	100,00	84,18	100,00

Çizelge 4.3. AstDem verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması

Litolojik Birimler	MLC		RF		SVM		ANN	
	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.
Alüvyon	95,65	100,00	100,00	100,00	96,52	100,00	95,65	100,00
Traverten	96,68	85,71	100,00	88,66	100,00	82,42	96,68	85,71
Peridotit	91,92	100,00	91,58	100	91,92	99,64	91,92	100,00
Kireçtaşı	89,31	80,32	95,93	83,96	94,40	73,90	89,31	80,32
Melanj	90,35	87,54	99,36	91,96	99,68	95,38	90,35	87,54
Klastikler	77,07	84,26	78,13	97,99	68,80	97,36	77,07	84,26
Çört	89,83	98,15	93,22	97,06	75,14	88,67	89,83	98,15

Çizelge 4.4. AstSen verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması

Litolojik Birimler	MLC		RF		SVM		ANN	
	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.
Alüvyon	91,30	94,17	90,87	99,05	77,83	97,28	91,30	94,17
Traverten	96,68	83,95	99,53	75,54	99,53	77,21	96,68	83,95
Peridotit	93,60	83,99	88,22	87,33	81,48	82,59	93,60	83,99
Kireçtaşı	94,15	88,10	95,42	97,66	97,71	95,05	94,15	88,10
Melanj	69,13	82,38	85,21	88,04	79,74	84,35	69,13	82,38
Klastikler	81,87	86,97	84,27	93,22	81,60	86,20	81,87	86,97
Çört	90,96	98,77	98,87	96,69	94,35	86,98	90,96	98,77

Çizelge 4.5. AstSenDem verisi kullanılarak yapılan sınıflandırmaların litolojik birimlerdeki üretici ve kullanıcı doğruluk değerlerinin karşılaştırması

Litolojik Birimler	MLC		RF		SVM		ANN	
	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.	Üreti.	Kulla.
Alüvyon	93,91	100,00	99,13	100,00	97,83	100,00	93,91	100,00
Traverten	96,68	86,08	100,00	89,03	100,00	78,15	96,68	86,08
Peridotit	89,90	100,00	93,27	100,00	93,27	98,23	89,90	100,00
Kireçtaşı	95,42	85,62	100,00	97,76	100,00	99,75	95,42	85,62
Melanj	82,64	86,53	96,46	93,75	96,78	97,41	82,64	86,53
Klastikler	86,40	85,04	87,47	96,76	75,20	95,92	86,40	85,04
Çört	90,40	98,77	96,05	89,01	98,87	79,55	90,40	98,77

Sınıflandırma sonrası tüm sınıflandırma sonuçlarına her bir birim için ROC eğrisi çizdirilerek AUC sonuçları elde edilmiştir (Çizelge 4.6-4.9). Elde edilen sonuçlar yapılan sınıflandırmaların iyi performans gösterdiğini belirtmektedir.

Çizelge 4.6. Ast verisinin her bir sınıflandırma için AUC sonuçları

Litolojik Birimler	MLC	RF	SVM	ANN
Alüvyon	0,978	0,989	0,982	0,975
Traverten	0,972	0,938	0,996	0,996
Peridotit	0,983	0,973	0,959	0,974
Kireçtaşı	0,902	0,951	0,962	0,944
Melanj	0,950	0,901	0,955	0,962
Klastikler	0,924	0,945	0,943	0,944
Çört	0,911	0,949	0,958	0,879

Çizelge 4.7. AstDem verisinin her bir sınıflandırma için AUC sonuçları

Litolojik Birimler	MLC	RF	SVM	ANN
Alüvyon	0,985	0,988	1	1
Traverten	0,972	1	1	1
Peridotit	0,985	0,973	0,970	0,959
Kireçtaşı	0,916	0,946	0,961	0,941
Melanj	0,934	0,998	0,968	0,992
Klastikler	0,918	0,943	0,948	0,951
Çört	0,921	0,874	0,958	0,826

Çizelge 4.8. AstSen verisinin her bir sınıflandırma için AUC sonuçları

Litolojik Birimler	MLC	RF	SVM	ANN
Alüvyon	0,976	0,989	0,982	0,989
Traverten	0,972	0,996	0,996	0,996
Peridotit	0,966	0,928	0,943	0,928
Kireçtaşı	0,955	0,981	0,967	0,981
Melanj	0,941	0,949	0,942	0,949
Klastikler	0,933	0,945	0,944	0,945
Çört	0,950	0,986	0,994	0,986

Çizelge 4.9. AstSenDem verisinin her bir sınıflandırma için AUC sonuçları

Litolojik Birimler	MLC	RF	SVM	ANN
Alüvyon	0,983	0,992	0,997	0,998
Traverten	0,972	1	1	1
Peridotit	0,961	0,976	0,975	0,984
Kireçtaşı	0,963	1	1	0,983
Melanj	0,962	0,989	0,966	0,969
Klastikler	0,932	0,948	0,953	0,947
Çört	0,944	0,998	0,976	0,998

Sınıflandırma sonrası her bir sınıflandırma için litolojik birimlerin sınıflandırma içindeki doğru piksel sayıları hesap ettirilmiştir (Çizelge 4.10-4.25).

Çizelge 4.10. Ast veri setinde MLC sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	215	0	0	0	0	9	0	0	224
Traverten	0	204	17	7	0	26	0	0	254
Peridotit	0	0	274	0	36	2	0	0	312
Kireçtaşı	2	1	0	339	6	36	19	1	404
Melanj	0	0	1	27	257	25	0	0	310
Klastikler	13	6	5	20	10	273	1	0	328
Çört	0	0	0	0	2	4	157	0	163
Su	0	0	0	0	0	0	0	38	38
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.11. Ast veri setinde RF sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	168	0	0	0	0	2	4	0	174
Traverten	0	197	33	14	1	36	0	0	281
Peridotit	0	0	236	0	44	1	0	0	281
Kireçtaşı	0	1	0	368	0	32	11	1	413
Melanj	0	0	28	0	266	19	0	0	313
Klastikler	52	13	0	0	0	280	2	0	347
Çört	10	0	0	11	0	5	160	0	186
Su	0	0	0	0	0	0	0	38	38
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.12. Ast veri setinde SVM sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	209	0	0	0	0	0	0	0	209
Traverten	0	210	16	14	6	31	0	0	277
Peridotit	0	0	261	0	36	1	0	0	298
Kireçtaşı	0	1	0	375	0	51	12	0	439
Melanj	0	0	20	1	265	12	0	0	298
Klastikler	21	0	0	3	4	280	0	0	308
Çört	0	0	0	0	0	0	165	0	165
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.13. Ast veri setinde ANN sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	207	0	0	0	0	2	0	0	209
Traverten	0	210	29	9	0	33	0	0	281
Peridotit	0	0	247	0	15	1	0	0	263
Kireçtaşı	0	0	0	370	0	27	27	2	426
Melanj	0	0	21	14	295	20	0	0	350
Klastikler	23	1	0	0	1	292	1	0	318
Çört	0	0	0	0	0	0	149	0	149
Su	0	0	0	0	0	0	0	37	37
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.14. AstSen veri setinde MLC sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	210	0	0	0	0	13	0	1	224
Traverten	0	204	9	7	3	20	0	0	243
Peridotit	0	0	278	0	51	2	0	0	331
Kireçtaşı	10	1	0	370	17	9	13	0	420
Melanj	0	0	10	13	215	23	0	0	261
Klastikler	10	6	0	3	24	307	3	6	359
Çört	0	0	0	0	1	1	161	0	163
Su	0	0	0	0	0	0	0	32	32
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.15. AstSen veri setinde RF sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	179	0	0	0	0	2	3	0	184
Traverten	0	210	20	4	0	38	0	0	272
Peridotit	0	0	242	0	50	1	0	0	293
Kireçtaşı	11	1	8	384	0	0	0	0	404
Melanj	0	0	27	1	248	13	5	0	294
Klastikler	30	0	0	4	13	306	2	0	355
Çört	10	0	0	0	0	15	167	0	192
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.16. AstSen veri setinde SVM sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	209	0	0	0	0	2	0	0	211
Traverten	0	210	13	18	0	37	0	0	278
Peridotit	0	0	262	0	36	2	0	0	300
Kireçtaşı	2	1	0	375	0	4	2	0	384
Melanj	0	0	22	0	265	14	0	0	301
Klastikler	13	0	0	0	10	316	0	0	339
Çört	6	0	0	0	0	0	175	0	181
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.17. AstSen veri setinde ANN sonrası birimlerin doğru piksel sayıları

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	221	0	0	7	0	2	0	0	230
Traverten	4	210	0	4	4	8	0	0	230
Peridotit	0	0	252	0	29	2	0	0	283
Kireçtaşı	2	1	22	360	0	0	9	2	396
Melanj	0	0	23	2	265	13	0	0	303
Klastikler	3	0	0	4	13	350	5	0	375
Çört	0	0	0	16	0	0	163	0	179
Su	0	0	0	0	0	0	0	37	37
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.18. AstDem veri setinde MLC sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	220	0	0	0	0	0	0	0	220
Traverten	0	204	17	0	0	17	0	0	238
Peridotit	0	0	273	0	0	0	0	0	273
Kireçtaşı	0	1	0	351	22	46	17	2	439
Melanj	0	0	2	18	281	20	0	0	321
Klastikler	10	6	5	24	8	289	1	0	343
Çört	0	0	0	0	0	3	159	0	162
Su	0	0	0	0	0	0	0	37	37
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.19. AstDem veri setinde RF sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	222	0	0	0	0	0	0	0	222
Traverten	0	211	24	7	1	13	0	0	256
Peridotit	1	0	273	0	0	0	0	0	274
Kireçtaşı	0	0	0	371	0	87	44	0	502
Melanj	0	0	0	15	310	0	0	0	325
Klastikler	7	0	0	0	0	258	0	0	265
Çört	0	0	0	0	0	17	133	0	150
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.20. AstDem veri setinde SVM sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	230	0	0	0	0	0	0	0	230
Traverten	0	211	17	0	0	10	0	0	238
Peridotit	0	0	272	0	0	0	0	0	272
Kireçtaşı	0	0	0	377	0	60	12	0	449
Melanj	0	0	8	12	309	7	0	0	336
Klastikler	0	0	0	4	2	293	0	0	299
Çört	0	0	0	0	0	5	165	0	170
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.21. AstDem veri setinde ANN sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	230	0	0	0	0	0	0	0	230
Traverten	0	211	41	1	7	19	0	0	279
Peridotit	0	0	232	0	0	0	0	0	232
Kireçtaşı	0	0	0	369	0	61	29	2	461
Melanj	0	0	24	20	304	1	0	0	349
Klastikler	0	0	0	3	0	288	11	0	302
Çört	0	0	0	0	0	6	137	0	143
Su	0	0	0	0	0	0	0	37	37
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.22. AstSenDem veri setinde MLC sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	216	0	0	0	0	0	0	1	217
Traverten	0	204	21	2	0	10	0	0	237
Peridotit	0	0	267	0	0	0	0	0	267
Kireçtaşı	4	1	0	375	23	17	14	6	440
Melanj	0	0	9	9	257	22	0	0	297
Klastikler	10	6	0	7	31	324	3	0	381
Çört	0	0	0	0	0	2	160	0	162
Su	0	0	0	0	0	0	0	32	32
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.23. AstSenDem veri setinde RF sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	225	0	0	0	0	0	0	0	225
Traverten	0	211	20	0	0	39	0	0	270
Peridotit	5	0	277	0	0	0	0	0	282
Kireçtaşı	0	0	0	393	0	1	0	0	394
Melanj	0	0	0	0	301	8	0	0	309
Klastikler	0	0	0	0	10	282	2	0	294
Çört	0	0	0	0	0	45	175	0	220
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033

Çizelge 4.24. AstSenDem veri setinde SVM sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	228	0	0	0	0	0	0	0	228
Traverten	2	211	13	0	0	11	0	0	237
Peridotit	0	0	277	0	0	0	0	0	277
Kireçtaşı	0	0	0	393	0	2	7	0	402
Melanj	0	0	7	0	300	13	0	0	320
Klastikler	0	0	0	0	11	328	0	0	339
Çört	0	0	0	0	0	21	170	0	191
Su	0	0	0	0	0	0	0	39	39
TOPLAM	230	211	297	393	311	375	177	39	2033


Çizelge 4.25. AstSenDem veri setinde ANN sonrası birimlerin doğru piksel sayısı

Litolojik Birimler	Alüvyon	Traverten	Peridotit	Kireçtaşı	Melanj	Klastikler	Çört	Su	Toplam
Alüvyon	228	0	0	0	0	0	0	0	228
Traverten	1	211	27	0	0	28	0	0	267
Peridotit	0	0	248	0	0	0	0	0	248
Kireçtaşı	0	0	0	382	2	2	0	2	388
Melanj	0	0	21	0	307	4	0	0	332
Klastikler	1	0	1	8	2	341	2	0	355
Çört	0	0	0	3	0	0	175	0	178
Su	0	0	0	0	0	0	0	37	37
TOPLAM	230	211	297	393	311	375	177	39	2033

5. TARTIŞMA

Sentinel-1 verileri litolojik ayırım için genellikle kullanılmayan veri setleridir. Sentinel-1 için yapılan çalışmalar; kırık, fay ve kıvrım gibi jeolojik anlamda yapısal verilerin ortaya çıkarılmasında (Adiri vd., 2017; Dhara vd., 2022; Javhar vd., 2019) yaşam alanı, tarım alanı, yeşil alanların tespiti gibi yüzey sınıflandırması konularında (Abdikan vd., 2016; Rao ve Kumar, 2017; Zhou vd., 2017) ve buzul çalışmalarında (Aldenhoff vd., 2016; Mouginot vd., 2017) olduğu görülmektedir. Bu çalışmada dahil olmak üzere son yıllarda Sentinel-1 verisinin litolojik sınıflandırmada kullanım potansiyeli araştırılmaya (Erith vd., 2020; Lu vd., 2021; Manap ve San, 2022; Shayeganpour vd., 2021) ve jeolojide farklı konularda da çalışılmaya başlanmıştır (Gee vd., 2019; Imamoglu vd., 2019; Nefeslioglu vd., 2021). Bu çalışmada birden çok veri seti ve yöntem test edilerek karşılaştırılmıştır.


Sınıflandırma sonrası her bir sınıf için litolojik birimlerin kullanıcı ve üretici doğruluk değerleri elde edilmiştir. Şekil 5.1'deki litolojik birimlerin kullanıcı doğruluk değerlerinin grafiklerine bakıldığında görülmektedir ki bazı birimlerin doğruluk değerleri diğerlerine göre daha düşük çıkmıştır.



Şekil 5.1. Litolojik birimlerin kullanıcı doğruluk değerleri grafik gösterimi


Çörtün Ast verisindeki tüm sınıflandırmalarda doğruluğunun düşük olduğu görülmektedir. Fakat Ast verisine veri eklenmesi ile bu birimin doğruluğunun yükseldiği görülmektedir. Melanj karmaşık bir litolojik birim olduğundan sınıflandırması oldukça zordur. Şekil 5.1'deki grafiklere bakıldığında da görülmektedir ki MLC sınıflandırması hem melanj hem kireçtaşını en kötü sınıflandıran yöntemdir. Arazi gözlemleri sırasında da MLC sınıflandırmasının kireçtaşı ile traverten ayırımında zorlandığı SVM

sınıflandırmasının bu ayrımı yapabildiği (Şekil 5.2 ve Şekil 5.3) görülmüştür. Klastiklerin doğruluk değerleri tüm sınıflandırma yöntemlerinde diğer birimlere oranla oldukça düşük çıkmıştır. Araziye çıkıldığında görülmüştür ki bu birimi en iyi sınıflandıran SVM tekniğidir. Sınıflandırma sonrası çıkılan arazide yamaç molozu olarak tespit edilen birimin MLC tarafından bir kısmının kireçtaşı bir kısmının klastikler olarak sınıflandırıldığı, RF tarafından bir kısmının melanj bir kısmının kireçtaşı bir kısmının klastikler olarak sınıflandırıldığı, SVM tarafından klastikler olarak sınıflandırıldığı, ANN tarafından bir kısmının traverten bir kısmının klastikler olarak sınıflandırıldığı görülmektedir (Şekil 5.4). Yamaç molozu büyük oranda her ne kadar kireçtaşının tektonik etkilerle kopan parçalanmış parçalarından oluşmuş olsa da klastikler biriminde olması gereken litolojik bir birimdir. Bu durumda SVM'nin en doğru sınıflandırma yöntemi olduğu ortaya çıkarılmıştır.




Şekil 5.2. Kireçtaşı ve klastiklerin AstSenDem veri setine SVM sınıflandırması sonucunun **a)** harita; **b)** arazi görüntüsü (36°51'07''K 30°20'06''D)

Arazi gözlemlerinde de görülmüştür ki SVM sınıflandırması özellikle kireçtaşı ve klastikler arasındaki ayrımı doğru bir şekilde yapabilmektedir (Şekil 5.2 ve Şekil 5.3). Klastikler olarak gruplandırıdığımız bu grupta bulunan kumtaşının sınıflandırmasının zor olduğunu Xie vd. (2018) çalışmasında belirtmiştir. Kireçtaşı, melanj ve klastiklerin sınıflandırılmasının zor olduğunu birimlerin doğru piksel sayılarının yer aldığı Çizelge 4.10 ve 4.25 arasındaki tüm çizelgeler incelendiğinde görülmektedir.



Şekil 5.3. Kireçtaşı ve klastiklerin AstSenDem veri setindeki SVM sınıflandırması sonucunun **a)** harita; **b)** arazi görüntüsü (36°50'20''K 30°19'58''D Saklıkent)



Şekil 5.4. K3 noktasındaki yamaç molozunun AstSenDem veri setindeki **a)** MLC; **b)** RF; **c)** SVM; **d)** ANN sınıflandırmasındaki sonuçları; **e)** arazi görüntüsü


Çalışma alanı geniş, ormanlık, bitki örtüsü bol, farklı yüksekliklere sahip alanların bulunduğu karmaşık bir arazidir. Hem melanj birimleri hem ofiyolitik birimlerin olması bunların kumtaşı çakıltası gibi klastik birimlerle birlikte bulunması sonucunda bu tür arazilerde hem jeolojik haritalama yapılması hem de uzaktan algılama verilerinin kullanılması oldukça karmaşık ve zordur. Literatürde gerçekleştirilen çalışmalar genellikle az bitki örtüsü kaplı, karmaşık (melanj vb.) litolojik birimlerin olmadığı görece olarak daha steril alanlarda yapılmıştır. Çalışma bu bakımdan diğer örneklerinden ayrılmaktadır.

Bitki örtüsünün maskelenmesi için bir yöntem ve ASTER görüntüsü için; $NDVI = \frac{b3 - b2}{b3 + b2}$ bant oranlaması olan NDVI kullanılarak bitki örtüsü dağılımı tespit edilmiştir (Çizelge 5.1).


Çizelge 5.1. Litolojik birimlerdeki bitki örtüsü dağılımı

Litolojik Birimler	Birimin toplam piksel sayısı	Birim içindeki NDVI piksel	Birim içindeki NDVI %
Alüvyon	848634	67255	7,93
Traverten	140898	46262	32,83
Peridotit	347023	22883	6,59
Kireçtaşı	7305877	512620	7,02
Melanj	1366115	150089	10,99
Klastikler	2628513	309455	11,77
Çört	413925	51120	12,35
TOPLAM	13062326	1162903	8,90


En düşük doğruluk değerlerine sahip olan Ast veri seti ile en yüksek doğruluk değerlerine sahip AstSenDem veri setinde NDVI ile maskeleme yapılarak MLC, RF ve ANN sınıflandırmaları uygulanmıştır. SVM sınıflandırmasında maskeleme olmadığından kullanılamamıştır. Yapılan tüm sınıflandırmalar deniz kısımları önceden maskelenerek o şekilde kaydedilen veri setlerine uygulanmıştır. NDVI maskelenerek yapılan MLC sınıflandırmasında deniz kısımları maskelenmiş olsa da bir birim olarak (yani su birimi olarak) sınıflandırdığı ve traverten birimini algılayamadığı görülmektedir (Şekil 5.5). ANN sınıflandırması da denizi maskelenmiş olmasına rağmen kireçtaşı birimi olarak sınıflandırdığı, bunun dışında AstSenDem veri setinin sınıflandırmasında ise traverten az da olsa ayırt edebildiği görülmektedir (Şekil 5.6). MLC ve ANN sınıflandırmalarının her ikisinde de traverten sınıflandırmada zorlansa da melanaj, kireçtaşı, klastikler ve alüvyonu sınıflandırmada sorun yaşamadıkları görülmektedir. RF sınıflandırmasında bu durum olmamıştır fakat bitki örtüsünün büyük bir kısmının travertende bulunduğu (Çizelge 5.1) bu birimi hiç sınıflandıramadığı görülmüştür (Şekil 5.7). Ayrıca Çizelge 4.10 ve 4.25 arasındaki sınıflandırmadaki doğru piksel sayılarının bulunduğu çizelgeler incelendiğinde maskelenmemiş sınıflandırmalarda travertende sorun yaşanmadığı sayısal olarak görülmektedir.



Şekil 5.5. NDVI maskelemesi yapılarak **a)** Ast veri setinde; **b)** AstSenDem veri setinde MLC sınıflandırması



Şekil 5.6. NDVI maskelemesi yapılarak **a)** Ast veri setinde; **b)** AstSenDem veri setinde ANN sınıflandırması



Şekil 5.7. NDVI maskelemesi yapılarak **a)** Ast veri setinde; **b)** AstSenDem veri setinde RF sınıflandırması

6. SONUÇLAR

Çalışma ASTER, Sentinel-1 ve ASTER GDEM verilerinin sınıflandırma girdisi olarak kullanılması ve farklı sınıflandırma tekniklerinin doğruluk değerlendirmeleri ile karşılaştırmalı bir çalışma yapılması amaçlanmıştır. Bu amaç doğrultusunda ASTER verisi tek olarak, DEM verisi ile birleştirilerek, polarimetrik SAR verisi birleştirilerek ve tüm verilerin birleştirilmesi ile oluşturulan girdi verilerinin sınıflandırmaya etkisi değerlendirilmiştir. İlgili çalışma Antalya'nın batısında bulunan Batı Toroslari içine alan bölgede litolojik ayırım için test edilmiştir.

Bu çalışma sonucunda hem DEM verisi hem de polarimetrik SAR verisi optik veriye eklenebileceği ve elde edilen genel doğruluk değerlerinin arttığı görülmüştür. Bu durum karmaşık litolojiye sahip alanlarda optik veri ile polarimetrik SAR ve DEM verilerinin etkin olarak kullanılabilirliğini ispatlamıştır.

Tez kapsamında uzaktan algılama tekniklerinden maksimum benzerlik sınıflandırması, makine öğrenme algoritmasından destek vektör makinaları ve rastgele orman sınıflandırmaları ile derin öğrenme algoritması olan yapay sinir ağları kullanılmıştır. Sınıflandırma teknikleri arasında MLC sınıflandırmasının en hızlı ama en düşük doğruluk değerlerine sahip sınıflandırma tekniği olduğu tespit edilmiştir. SVM sınıflandırması uygulanan sınıflandırma teknikleri içerisinde genel doğruluk değerlerine göre en yüksek değerlere sahip olduğu görülmüştür. Buna karşın SVM sınıflandırması eğitim aşaması en uzun süre alan teknik olmuştur. ANN tekniğinin SVM tekniği gibi doğruluk derecesi yüksek sonuçlar verdiği görülmüş, SVM tekniğinden daha kısa sürede sınıflandırma yapması açısından oldukça avantajlı olduğu tespit edilmiştir. Fakat ANN tekniğinde çok fazla parametre olduğundan ilk aşamada bunların optimize edilmesi gerekmektedir. RF tekniği hem hız bakımından hem doğruluk değerleri bakımından diğer makina öğrenme algoritmalarına kıyasla orta derecede doğruluk değerleri sunmaktadır.

Bu çalışmada ayrıca ince kesit örnekleri tek nikol ve çift nikol görüntülerinin farklı açılarda görüntüleri alınarak üst üste çakıştırma tekniği ile elde edilen veriye sınıflandırma yapılabileceği görülmüştür.

Elde edilen bulgular doğrultusunda SMA tekniğinin uygulanabilir bir teknik olduğu ve bölgeye ait spektral imzalar olmadığı durumlarda minerallerin oranlarına göre uygulanarak bölge hakkında bilgi edinilebileceği görülmüştür.

Çalışma kapsamında hem veri setleri kendi içinde hem de sınıflandırma teknikleri birbirleriyle karşılaştırılmış ayrıca arazi doğrulaması elde edilen sonuçlar kontrol edilmiştir. Hem elde edilen toplam doğruluk değeri sonuçları hem de arazide yapılan gözlemler doğrultusunda optik verilere DEM ve polarimetrik SAR verisi eklenmesinin sınıflandırmayı olumlu yönde etkilediği tespit edilmiştir. Çalışmada elde edilen sonuçlar farklı veri setlerinin litolojik sınıflandırma için etkin kullanılabilirliğini arttırdığı sonucuna varılmıştır.

7. KAYNAKLAR

- Abdikan, S., Sanli, F.B., Ustuner, M., Calò, F., 2016. Land Cover Mapping Using Sentinel-1 Sar Data. *ISPRS - Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* XLI-B7, 757–761. <https://doi.org/10.5194/isprsarchives-XLI-B7-757-2016>
- Ada, M., San, B.T., 2018. Comparison of machine-learning techniques for landslide susceptibility mapping using two-level random sampling (2LRS) in Alakir catchment area, Antalya, Turkey. *Nat. Hazards* 90, 237–263. <https://doi.org/10.1007/s11069-017-3043-8>
- Adiri, Z., El Harti, A., Jellouli, A., Lhissou, R., Maacha, L., Azmi, M., Zouhair, M., Bachaoui, E.M., 2017. Comparison of Landsat-8, ASTER and Sentinel 1 satellite remote sensing data in automatic lineaments extraction: A case study of Sidi Flah-Bouskour inlier, Moroccan Anti Atlas. *Adv. Sp. Res.* 60, 2355–2367. <https://doi.org/10.1016/j.asr.2017.09.006>
- Akgün, E., İnceöz, M., Manap, H.S., 2021. Aktif Tektonikte Uzaktan Algılama Uygulamaları: Doğu Anadolu Fay Zonu’ndan Bir Örnek. *Çukurova Üniversitesi Mühendislik Fakültesi Derg.* 36, 473–482.
- Aktas, H., San, B.T., 2019. Landslide susceptibility mapping using an automatic sampling algorithm based on two level random sampling. *Comput. Geosci.* 133, 104329. <https://doi.org/10.1016/j.cageo.2019.104329>
- Aldenhoff, W., Berg, A., Eriksson, L.E.B., 2016. Sea ice concentration estimation from Sentinel-1 Synthetic Aperture Radar images over the Fram Strait, in: International Geoscience and Remote Sensing Symposium (IGARSS). IEEE, pp. 7675–7677. <https://doi.org/10.1109/IGARSS.2016.7731001>
- Attema, E., Bargellini, P., Edwards, P., Levrini, G., Lokas, S., Moeller, L., Rosich-Tell, B., Secchi, P., Torres, R., Davidson, M., Snoeij, P., 2007. Sentinel-1 The Radar Mission for GMES Operational Land and Sea Services. *esa Bull.* 131 11–17.
- Bachri, I., Hakdaoui, M., Raji, M., Teodoro, A.C., Benbouziane, A., 2019. Machine learning algorithms for automatic lithological mapping using remote sensing data: A case study from Souk Arbaa Sahel, Sidi Ifni Inlier, Western Anti-Atlas, Morocco. *ISPRS Int. J. Geo-Information* 8. <https://doi.org/10.3390/ijgi8060248>
- Bağcı, U., Parlak, O., 2009. Petrology of the tekirova (Antalya) ophiolite (Southern Turkey): Evidence for diverse magma generations and their tectonic implications during Neotethyan-subduction. *Int. J. Earth Sci.* 98, 387–405. <https://doi.org/10.1007/s00531-007-0242-7>
- Bağcı, U., Parlak, O., Höck, V., 2006. Geochemical character and tectonic environment of ultramafic to mafic cumulate rocks from the Tekirova (Antalya) ophiolite (southern Turkey). *Geol. J.* 41, 193–219. <https://doi.org/10.1002/gj.1035>
- Bahrambeygi, B., Moeinzadeh, H., 2017. Comparison of support vector machine and neutral network classification method in hyperspectral mapping of ophiolite

- mélanges—A case study of east of Iran. Egypt. *J. Remote Sens. Sp. Sci.* 20, 1–10. <https://doi.org/10.1016/j.ejrs.2017.01.007>
- Bedini, E., 2011. Mineral mapping in the Kap Simpson complex, central East Greenland, using HyMap and ASTER remote sensing data. *Adv. Sp. Res.* 47, 60–73. <https://doi.org/10.1016/j.asr.2010.08.021>
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Chen, D., Stow, D., 2002. The Effect of Training Strategies on Supervised Classification at Different Spatial Resolutions. *Photogramm. Eng. Remote Sens.* 68, 1155–1161.
- Chen, X., Warner, T.A., Campagna, D.J., 2007. Integrating visible, near-infrared and short wave infrared hyperspectral and multispectral thermal imagery for geologic mapping: Simulated data. *Int. J. Remote Sens.* 28, 2415–2430. <https://doi.org/10.1080/01431160600702624>
- Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educ. Psychol. Meas.* 20, 37–46.
- Cortes, C., Vapnik, V., 1995. Support-Vector Networks. *Mach. Learn.* 20, 273–297. <https://doi.org/10.1109/64.163674>
- Cracknell, M.J., Reading, A.M., 2014. Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. *Comput. Geosci.* 63, 22–33. <https://doi.org/10.1016/j.cageo.2013.10.008>
- Cui, J., Yan, B., Dong, X., Zhang, S., Zhang, J., Tian, F., Wang, R., 2015. Temperature and emissivity separation and mineral mapping based on airborne TASI hyperspectral thermal infrared data. *Int. J. Appl. Earth Obs. Geoinf.* 40, 19–28. <https://doi.org/10.1016/j.jag.2015.03.014>
- Dhara, M., Baisantry, M., Prusty, G., 2022. Automatic extraction and analysis of lineament features using ASTER and Sentinel 1 SAR data. *J. Earth Syst. Sci.* 131. <https://doi.org/10.1007/s12040-022-01851-y>
- Erith, M., Jhonatan, E., Daniel, T., Marielisa, B., Franz, B., Carmen, S., Victor, P., Aracely, L., Alfonso, Z., 2020. Automate Lithological Classification of the Amotape Tahuin Metamorphic Complex in Ecuador using Random Forest and a Multi-Sensor Satellite Imagery Approach, in: International Geoscience and Remote Sensing Symposium (IGARSS). pp. 2093–2096. <https://doi.org/10.1109/IGARSS39084.2020.9323942>
- Eslami, A., Ghaderi, M., Rajendran, S., Pour, A.B., Hashim, M., 2015. Integration of ASTER and landsat TM remote sensing data for chromite prospecting and lithological mapping in Neyriz ophiolite zone, south Iran. *Resour. Geol.* 65, 375–388. <https://doi.org/10.1111/rge.12076>

- Fleiss, J.L., 1971. Measuring nominal scale agreement among many raters. *Psychol. Bull.* 76, 378–382.
- Ge, W., Cheng, Q., Jing, L., Armenakis, C., Ding, H., 2018. Lithological discrimination using ASTER and Sentinel-2A in the Shibanzing ophiolite complex of Beishan orogenic in Inner Mongolia, China. *Adv. Sp. Res.* 62, 1702–1716. <https://doi.org/10.1016/j.asr.2018.06.036>
- Gee, D., Sowter, A., Grebby, S., de Lange, G., Athab, A., Marsh, S., 2019. National geohazards mapping in Europe: Interferometric analysis of the Netherlands. *Eng. Geol.* 256, 1–22. <https://doi.org/10.1016/j.enggeo.2019.02.020>
- Grebby, S., Naden, J., Cunningham, D., Tansey, K., 2011. Integrating airborne multispectral imagery and airborne LiDAR data for enhanced lithological mapping in vegetated terrain. *Remote Sens. Environ.* 115, 214–226. <https://doi.org/10.1016/j.rse.2010.08.019>
- Gualtieri, J.A., Crompton, R., 1998. SVM for Hyperspectral Remote Sensing Classification. *Proc. SPIE* 3584, 221–232.
- Günay, Y., Bölükbaşı, A.S., Yoldemir, O., 1982. Beydağlarının Stratigrafisi ve Yapısı, in: *Türkiye Altıncı Petrol Kong. Tebl.* pp. 91–101.
- Güneş, A., İlbeyli, N., Rasingil, S., Demirbilek, M., 2021. Petrological and geochemical characteristics of the diabase and metasomatised dikes from the Tekirova ophiolite (SW Anatolia, Turkey): Tectonomagmatic evolution of the southern Neotethys. *Geochemistry* 81. <https://doi.org/10.1016/j.chemer.2021.125767>
- Harvey, A.S., Fotopoulos, G., 2016. Geological mapping using machine learning algorithms. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.* 41, 423–430. <https://doi.org/10.5194/isprsarchives-XLI-B8-423-2016>
- Hassan, S.M., Sadek, M.F., 2017. Geological mapping and spectral based classification of basement rocks using remote sensing data analysis: The Korbiai-Gerf nappe complex, South Eastern Desert, Egypt. *J. African Earth Sci.* 134, 404–418. <https://doi.org/10.1016/J.JAFREARSCI.2017.07.006>
- Hassler, E.R., Swihart, G.H., Dye, D.H., Li, Y.S., 2013. Non-destructive provenance study of chert using infrared reflectance microspectroscopy. *J. Archaeol. Sci.* 40, 2001–2006. <https://doi.org/10.1016/j.jas.2012.12.028>
- Haykin, S., 1994. *Neural Networks - A Comprehensive Foundation*. Prentice Hall.
- He, J., Harris, J.R., Sawada, M., Behnia, P., 2015. A comparison of classification algorithms using Landsat-7 and Landsat-8 data for mapping lithology in Canada's Arctic. *Int. J. Remote Sens.* 36, 2252–2276. <https://doi.org/10.1080/01431161.2015.1035410>
- Ho, T.K., 1995. Random Decision Forests, in: *IEEE*. pp. 278–282.

- Huang, C., Davis, L.S., Townshend, J.R.G., 2002. An assessment of support vector machines for land cover classification. *Int. J. Remote Sens.* 23, 725–749. <https://doi.org/10.1080/01431160110040323>
- Huang, H., Legarsky, J., Othman, M., 2007. Land-cover Classification Using Radarsat and Landsat Imagery for St . Louis , Missouri. *Photogramm. Eng. Remote Sens.* 73, 037–043. <https://doi.org/10.14358/PERS.73.1.37>
- Imamoglu, M., Kahraman, F., Cakir, Z., Sanli, F.B., 2019. Ground deformation analysis of Bolvadin (W. Turkey) by means of multi-temporal InSAR techniques and sentinel-1 data. *Remote Sens.* 11, 1–17. <https://doi.org/10.3390/rs11091069>
- J. Anthony Gualtieri; R. F. Crompton, 1999. Support Vector Machines for Hyperspectral Remote Sensing. Scikit-Learn 0.18.1 Doc.
- Javhar, A., Chen, X., Bao, A., Jamshed, A., Yunus, M., Jovid, A., Latipa, T., 2019. Comparison of multi-resolution optical Landsat-8, Sentinel-2 and radar Sentinel-1 data for automatic lineament extraction: A case study of Alichur area, SE Pamir. *Remote Sens.* 11, 1–29. <https://doi.org/10.3390/rs11070778>
- Juteau, T., 1975. Les ophiolites des nappes d’Antalya (Taurides occidentales Turquie): These Sc. de la Terre. Nancy. Terre.
- Kalafatçıoğlu, A., 1973. Antalya Körfezi Batı Kısımının Jeolojisi. *MTA Derg.* 81, 82–131.
- Kavak, K.S., 2005. Recognition of gypsum geohorizons in the Sivas Basin (Turkey) using ASTER and Landsat ETM+ images. *Int. J. Remote Sens.* 26, 4583–4596. <https://doi.org/10.1080/01431160500185607>
- Khan, S.D., Mahmood, K., 2008. The application of remote sensing techniques to the study of ophiolites. *Earth-Science Rev.* 89, 135–143. <https://doi.org/10.1016/j.earscirev.2008.04.004>
- Kodikara, G.R.L., Woldai, T., van Ruitenbeek, F.J.A., Kuria, Z., van der Meer, F., Shepherd, K.D., van Hummel, G.J., 2012. Hyperspectral remote sensing of evaporate minerals and associated sediments in Lake Magadi area, Kenya. *Int. J. Appl. Earth Obs. Geoinf.* 14, 22–32. <https://doi.org/10.1016/j.jag.2011.08.009>
- Kruse, F.A., 2012. Mapping surface mineralogy using imaging spectrometry. *Geomorphology* 137, 41–56. <https://doi.org/10.1016/j.geomorph.2010.09.032>
- Kruse, F.A., Lefkoff, A.B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A.T., Barloon, P.J., Goetz, A.F.H., 1993. The Spectral Image Processing System (SIPS) – Interactive Visualization and Analysis of Imaging Spectrometer Data. *Remote Sens. Environ.* 44, 145–163.
- Lary, D.J., Alavi, A.H., Gandomi, A.H., Walker, A.L., 2016. Machine learning in geosciences and remote sensing. *Geosci. Front.* 7, 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>

- Lefevre, R., 1967. Un nouvel element de la geologie du Taurus Lycien: les nappes d'Antalya (Turquie). *CR.Ac. Sciences* 263, 1029–1032.
- Liu, L., Zhou, J., Jiang, D., Zhuang, D., Mansaray, L.R., Hu, Z., Ji, Z., 2016. Mineral resources prospecting by synthetic application of TM/ETM+, Quickbird and Hyperion data in the Hatu area, West Junggar, Xinjiang, China. *Sci. Rep.* 6, 1–14. <https://doi.org/10.1038/srep21851>
- Liu, L., Zhuang, D.F., Zhou, J., Qiu, D.S., 2011. Alteration mineral mapping using masking and Crosta technique for mineral exploration in mid-vegetated areas: A case study in Areletuobie, Xinjiang (China). *Int. J. Remote Sens.* 32, 1931–1944. <https://doi.org/10.1080/01431161003639678>
- Lu, Y., Yang, C., Meng, Z., 2021. Lithology discrimination using sentinel-1 dual-pol data and srtm data. *Remote Sens.* 13. <https://doi.org/10.3390/rs13071280>
- Maepa, F., Smith, R.S., Tessema, A., 2021. Support vector machine and artificial neural network modelling of orogenic gold prospectivity mapping in the Swayze greenstone belt, Ontario, Canada. *Ore Geol. Rev.* 130. <https://doi.org/10.1016/j.oregeorev.2020.103968>
- Mahvash Mohammadi, N., Hezarkhani, A., 2018. Application of support vector machine for the separation of mineralised zones in the Takht-e-Gonbad porphyry deposit, SE Iran. *J. African Earth Sci.* 143, 301–308. <https://doi.org/10.1016/J.JAFREARSCI.2018.02.005>
- Manap, H.S., San, B.T., 2022. Data Integration for Lithological Mapping Using Machine Learning Algorithms. *Earth Sci. Informatics* publishing. <https://doi.org/10.1007/s12145-022-00826-3>
- Mars, J.C., Rowan, L.C., 2010. Spectral assessment of new ASTER SWIR surface reflectance data products for spectroscopic mapping of rocks and minerals. *Remote Sens. Environ.* 114, 2011–2025. <https://doi.org/10.1016/j.rse.2010.04.008>
- MGM, 2022. Meteoroloji Genel Müdürlüğü [WWW Document]. URL <https://mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=ANTALYA>. Accessed 30.03.2022
- Molan, Y.E., Refahi, D., Tarashti, A.H., 2014. Mineral mapping in the Maherabad area, eastern Iran, using the hyMap remote sensing data. *Int. J. Appl. Earth Obs. Geoinf.* 27, 117–127. <https://doi.org/10.1016/j.jag.2013.09.014>
- Momeni, R., Aplin, P., Boyd, D.S., 2016. Mapping complex urban land cover from spaceborne imagery: The influence of spatial resolution, spectral band set and classification approach. *Remote Sens.* 8. <https://doi.org/10.3390/rs8020088>
- Mouginot, J., Rignot, E., Scheuchl, B., Millan, R., 2017. Comprehensive annual ice sheet velocity mapping using Landsat-8, Sentinel-1, and RADARSAT-2 data. *Remote Sens.* 9, 1–20. <https://doi.org/10.3390/rs9040364>

- Mountrakis, G., Im, J., Ogole, C., 2011. Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* 66, 247–259. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Nefeslioglu, H.A., Tavus, B., Er, M., Ertugrul, G., Ozdemir, A., Kaya, A., Kocaman, S., 2021. Integration of an InSAR and ANN for sinkhole susceptibility mapping: A case study from kirikkale-delice (Turkey). *ISPRS Int. J. Geo-Information* 10, 119. <https://doi.org/10.3390/ijgi10030119>
- Negnevitsky, M., 2005. Artificial Intelligence- A Guide to Intelligent Systems, Addison Wesley. <https://doi.org/10.1016/j.poly.2016.11.012>
- Ni, C., Zhang, S., Chen, Z., Yan, Y., Li, Y., 2017. Mapping the Spatial Distribution and Characteristics of Lineaments Using Fractal and Multifractal Models: A Case Study from Northeastern Yunnan Province, China. *Sci. Rep.* 7, 1–11. <https://doi.org/10.1038/s41598-017-11027-0>
- OGM, 2022. Orman Genel Müdürlüğü [WWW Document]. URL [https://www.ogm.gov.tr/tr/e-kutuphane-sitesi/Yayinlar/Orman Atlasi.pdf](https://www.ogm.gov.tr/tr/e-kutuphane-sitesi/Yayinlar/Orman%20Atlasi.pdf). Accessed 31.03.2022
- Olivares, M., Tarriño, A., Murelaga, X., Baceta, J.I., Castro, K., Etxebarria, N., 2009. Non-destructive spectrometry methods to study the distribution of archaeological and geological chert samples. *Spectrochim. Acta - Part A Mol. Biomol. Spectrosc.* 73, 492–497. <https://doi.org/10.1016/j.saa.2008.12.036>
- Othman, A.A., Gloaguen, R., 2017. Integration of spectral, spatial and morphometric data into lithological mapping: A comparison of different Machine Learning Algorithms in the Kurdistan Region, NE Iraq. *J. Asian Earth Sci.* 146, 90–102. <https://doi.org/10.1016/j.jseaes.2017.05.005>
- Othman, A.A., Gloaguen, R., 2014. Improving lithological mapping by SVM classification of spectral and morphological features: The discovery of a new chromite body in the Mawat ophiolite complex (Kurdistan, NE Iraq). *Remote Sens.* 6, 6867–6896. <https://doi.org/10.3390/rs6086867>
- Oztan, N.S., Süzen, M.L., 2011. Mapping evaporate minerals by ASTER. *Int. J. Remote Sens.* 32, 1651–1673. <https://doi.org/10.1080/01431160903586799>
- Poisson, A., 1977. Recherches géologiques dans les Taurides occidentales (Turquie). Paris-Sud.
- Pour, A.B., Hashim, M., van Genderen, J., 2013. Detection of hydrothermal alteration zones in a tropical region using satellite remote sensing data: Bau goldfield, Sarawak, Malaysia. *Ore Geol. Rev.* 54, 181–196. <https://doi.org/10.1016/j.oregeorev.2013.03.010>
- Pournamdari, M., Hashim, M., 2014. Detection of chromite bearing mineralized zones in Abdasht ophiolite complex using ASTER and ETM+ remote sensing data. *Arab. J. Geosci.* 7, 1973–1983. <https://doi.org/10.1007/s12517-013-0927-0>

- Pournamdari, M., Hashim, M., Pour, A.B., 2014. Application of ASTER and Landsat TM data for geological mapping of esfandagheh ophiolite complex, southern Iran. *Resour. Geol.* 64, 233–246. <https://doi.org/10.1111/rge.12038>
- Radford, D.D.G., Cracknell, M.J., Roach, M.J., Cumming, G. V., 2018. Geological Mapping in Western Tasmania Using Radar and Random Forests. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* 11, 3075–3087. <https://doi.org/10.1109/JSTARS.2018.2855207>
- Rajendran, S., Nasir, S., 2015. Mapping of high pressure metamorphics in the As Sifah region, NE Oman using ASTER data. *Adv. Sp. Res.* 55, 1134–1157. <https://doi.org/10.1016/j.asr.2014.11.026>
- Rajendran, S., Nasir, S., 2014. ASTER spectral sensitivity of carbonate rocks - Study in Sultanate of Oman. *Adv. Sp. Res.* 53, 656–673. <https://doi.org/10.1016/j.asr.2013.11.047>
- Rao, K.V.R., Kumar, P.P.R., 2017. Land Cover Classification Using Sentinel-1 SAR Data 5, 1054–1060.
- Reuber, I., 1982. Generations successives de filons grenus dans le complexe ophiolitique d'Antalya (Turquie). Origine evolution et mecanismes d'injection des liquides. U.E.R. Des Sciences Terre.
- Rice, M.S., Bell, J.F., Cloutis, E.A., Wang, A., Ruff, S.W., Craig, M.A., Bailey, D.T., Johnson, J.R., de Souza, P.A., Farrand, W.H., 2010. Silica-rich deposits and hydrated minerals at Gusev Crater, Mars: Vis-NIR spectral characterization and regional mapping. *Icarus* 205, 375–395. <https://doi.org/10.1016/j.icarus.2009.03.035>
- Richards, J.A., 1999. Remote Sensing Digital Image Analysis. Springer-Verlag, Berlin.
- Richards, J.A., Jia, X., 2006. Remote Sensing Digital Image Analysis. Springer-Verlag, Berlin Heidelberg, Germany.
- Rowan, L.C., Mars, J.C., Simpson, C.J., 2005. Lithologic mapping of the Mordor, NT, Australia ultramafic complex by using the Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER). *Remote Sens. Environ.* 99, 105–126. <https://doi.org/10.1016/j.rse.2004.11.021>
- Sabins, F.F., 1999. Remote sensing for mineral exploration. *Ore Geol. Rev.* 14, 157–183. [https://doi.org/10.1016/S0169-1368\(99\)00007-4](https://doi.org/10.1016/S0169-1368(99)00007-4)
- San, B.T., 2014. An evaluation of SVM using polygon-based random sampling in landslide susceptibility mapping: The Candir catchment area (western Antalya, Turkey). *Int. J. Appl. Earth Obs. Geoinf.* <https://doi.org/10.1016/j.jag.2013.09.010>
- Şenel, M., 1997. 1:100 000 ölçekli Türkiye Jeoloji Haritaları. Ankara.
- Senel, M., Selçuk, H., Bigin, Z.R., Sen, A.M., Karaman, T., Erkan, M., Kaymakçı, H.,

- Orçen, S., Bilgi, C., 1987. Likya napları ön cephe özellikleri (GB, Türkiye), in: Türkiye Jeoloji Kurultayı. p. 6.
- Şenel, M., Serdaroglu, M., Kengil, R., Unverdi, M., Gozler, M.Z., 1981. Teke toroslari güneydoğusunun jeolojisi. *MTA Derg.* 95, 13–43.
- Sengupta, A., Adhikari, M. Das, Maiti, S., Maiti, S.K., Mahanta, P., Bhaumick, S., 2019. Identification and mapping of high-potential iron ore alteration zone across Joda, Odisha using ASTER and EO-1 hyperion data. *J. Spat. Sci.* 64, 491–514. <https://doi.org/10.1080/14498596.2018.1485120>
- Shayeganpour, S., Tangestani, M.H., Gorsevski, P. V., 2021. Machine learning and multi-sensor data fusion for mapping lithology: A case study of Kowli-kosh area, SW Iran. *Adv. Sp. Res.* 68, 3992–4015. <https://doi.org/10.1016/j.asr.2021.08.003>
- Smith, M.R., Bandfield, J.L., Cloutis, E.A., Rice, M.S., 2013. Hydrated silica on Mars: Combined analysis with near-infrared and thermal-infrared spectroscopy. *Icarus* 223, 633–648. <https://doi.org/10.1016/j.icarus.2013.01.024>
- Tagnon, B.O., Assoma, V.T., Mangoua, J.M.O., Douagui, A.G., Kouamé, F.K., Savané, I., 2020. Contribution of SAR/RADARSAT-1 and ASAR/ENVISAT images to geological structural mapping and assessment of lineaments density in Divo-Oume area (Côte d’Ivoire). *Egypt. J. Remote Sens. Sp. Sci.* 23, 231–241. <https://doi.org/10.1016/j.ejrs.2018.12.001>
- Tangestani, M.H., Jaffari, L., Vincent, R.K., Sridhar, B.B.M., 2011. Spectral characterization and ASTER-based lithological mapping of an ophiolite complex: A case study from Neyriz ophiolite, SW Iran. *Remote Sens. Environ.* 115, 2243–2254. <https://doi.org/10.1016/j.rse.2011.04.023>
- Teikeu, W., Njandjock, P., Tabod, C., Martial, J., Nshagali, G., 2016. Hydrogeological activity of lineaments in Yaounde Cameroon region using remote sensing and GIS techniques. *Egypt. J. Remote Sens. Sp.* 49–60. <https://doi.org/10.1016/j.ejrs.2015.12.006>
- Vapnik, V., 1999. The Nature of Statistical Learning Theory, Second edi. ed. Springer US, New York.
- Wang, G., Du, W., Carranza, E.J.M., 2017. Remote sensing and GIS prospectivity mapping for magmatic-hydrothermal base- and precious-metal deposits in the Honghai district, China. *J. African Earth Sci.* 128, 97–115. <https://doi.org/10.1016/j.jafrearsci.2016.06.020>
- Weilin, Y., Yan, M., Shengwei, L., 2016. Application of Radar and Optical Remote Sensing Data in Lithologic Classification and Identification, in: IGARSS 2016. pp. 6370–6373.
- Xie, Y., Zhu, C., Zhou, W., Li, Z., Liu, X., Tu, M., 2018. Evaluation of machine learning methods for formation lithology identification: A comparison of tuning processes and model performances. *J. Pet. Sci. Eng.* 160, 182–193.

<https://doi.org/10.1016/j.petrol.2017.10.028>

Yu, L., Porwal, A., Holden, E.J., Dentith, M.C., 2012. Towards automatic lithological classification from remote sensing data using support vector machines. *Comput. Geosci.* 45, 229–239. <https://doi.org/10.1016/j.cageo.2011.11.019>

Zhang, H., Wang, Y., Li, Y., 2009. SVM model for estimating the parameters of the probability-integral method of predicting mining subsidence. *Min. Sci. Technol.* 19, 385–388. [https://doi.org/10.1016/S1674-5264\(09\)60072-7](https://doi.org/10.1016/S1674-5264(09)60072-7)


Zhou, S., Deng, Y., Wang, R., Li, N., Si, Q., 2017. Effective Mapping of Urban Areas Using ENVISAT ASAR, Sentinel-1A, and HJ-1-C Data. *IEEE Geosci. Remote Sens. Lett.* 14, 891–895. <https://doi.org/10.1109/LGRS.2017.2686419>




8. EKLER

EK-1. Örneklerin ince kesit analizleri


Örnek Numarası	Mikroskop gözlemi	Kayaç Adı
K01	Serpantin, kalsit, klorit	Serpantinit
K02A	Klinopiroksen, ortopiroksen, plajiyoklaz, serpantin	Altere gabro?/dünit?
K02B	Serpantine dönüşmüş piroksen ve az oranda olivin kalıntıları	Serpantine harzburjıt
K03	Plajiyoklaz, ortopiroksen, klinopiroksen, klorit	Piroksenit
K04	Plajiyoklaz, klinopiroksen	Gabro
K05	Serpantin, ortopiroksen, ortopiroksenden dönüşen klinopiroksen, manyezit	Serpantinit
K06	Plajiyoklaz, uralitleşme kloritleşme gösteren klinopiroksen	Mikro Gabro
K07	Serpantin, rutil, opak min.	Serpantinit
K08A	Yoğun killeşme hâkim aşırı altere olmuş subvolkanik	Altere bazalt
K08B	Serpantine dönüşmüş olivin kalıntıları, rutil, klorit	Serpantinit
K09	Plajiyoklaz, uralitleşme kloritleşme gösteren klinopiroksen	Mikro Gabro
K010A	Sosuritleşme gösteren plajiyoklaz, uralitleşme, epidotlaşma gösteren amfibole dönüşmüş piroksenler	Gabro
K010B	Serpantin, biyotit, kalsit, serizit, rutil	Serpantinit
K011	Serpantin, klinopiroksen kalıntısı, rutil	Serpantinit
K012A	Plajiyoklaz, rodenjitleşmiş piroksenler	Dolerit/Diyabaz
K012B	Serpantin, biyotitleşmiş piroksen dönüşümleri	Serpantinit
K013A	Plajiyoklaz, rodenjitleşmiş piroksenler	Dolerit/Diyabaz
K013B	Plajiyoklaz, rodenjitleşmiş piroksenler	Dolerit/Diyabaz
K014	Amfibol, kuvars, plajiyoklaz, biyotit	Monzonit?

EK-2. Örneklerin spektral eğrileri**K01****K02A****K02B**


K03




K04




K05




K06




K07



K08A




K08B




K09




K010A




K010B




K011




K012A




K012B




K013A



K013B



K014



ÖZGEÇMİŞ

HATİCE SEVAL MANAP

ÖĞRENİM BİLGİLERİ

Doktora 2014-2022	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği ABD, Antalya
Yüksek Lisans 2011-2014	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği ABD, Antalya
Lisans 2005-2009	Akdeniz Üniversitesi Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Antalya

MESLEKİ VE İDARİ GÖREVLER

Araştırma Görevlisi 2014-2022	Akdeniz Üniversitesi Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Antalya
----------------------------------	--

ESERLER

Uluslararası hakemli dergilerde yayımlanan makaleler

1. **Manap H. S.**, San B. T. (2022) Data Integration for Lithological Mapping Using Machine Learning Algorithms. Earth Science Informatics (Publishing). Doi: 10.1007/s12145-022-00826-3
2. Erkül F., Erkul S., **Manap H. S.**, Çolak C. (2017) An extensional and transtensional origin of elongated magmatic domes and localised transfer faults in the northern Menderes metamorphic core complex, western Turkey. Geodinamica Acta, cilt.29, sa.1, ss.139-159 (SCI İndekslerine Giren Dergi)

Ulusal ve uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1. Akgün E., **Manap H. S.**, İnceöz M. (2019) Remote Sensing Application to an active fault segment on the East Anatolian Fault Zone. 23. Aktif Tektonik Araştırma Grubu (ATAG23), İstanbul, Türkiye, 15- 18 Ekim 2019, ss.1
2. Akgün E., İnceöz M., **Manap H. S.** (2019) Geological Lineament Analyses Application to a Fault Segment on The East Anatolian Fault Zone. 19th International Scientific GeoConference SGEM 2019, Albena, Bulgaristan, 28 Haziran- 07 Temmuz 2019, cilt.2, sa.2, ss.547-552
3. **Manap H. S.**, San B. T. (2018) Lithological Mapping Using Different Classification Algorithms in Western Antalya, Turkey. 18th International Multidisciplinary Scientific GeoConference SGEM 2018, Albena, Bulgaristan, 2- 08 Temmuz 2018, cilt.18, ss.551-556
4. **Manap H. S.**, San B. T. (2018) Machine Learning Classification Algorithms: Case Study of Western Antalya, Turkey. 9th International Symposium on Eastern Mediterranean Geology, Antalya, Türkiye, 7- 11 Mayıs 2018, cilt.1, sa.1, ss.60-61
5. Erkül F., **Manap H. S.**, Tatar Erkül S., Çolak C. (2016) Heterojen genişleme altında gelişen sığ yerleşimli granitoidlerin yapısal analizi: Eğrigöz ve Koyunoba granitleri, Batı Anadolu. 69. Türkiye Jeoloji Kurultayı, Ankara, Türkiye, 11- 15 Nisan 2016, cilt.1, sa.1, ss.1
6. **Manap H. S.**, Erkül F., Tatar Erkül S., Çolak C. (2015) Exhumation And Emplacement Of A Shallow-Seated Granitoids In Extensional Coupled With Compressional Setting: The Eğrigöz Granite, Western Turkey. EGU-2015, Vienna, Avusturya, 12- 17 Nisan 2015, cilt.17, sa.1, ss.1
7. **Manap H. S.**, Özaksoy V., Gürboğa Ş. (2014) Antalya Tufalarının Yapısal Özellikleri. 67. Türkiye Jeoloji Kurultayı, Ankara, Türkiye, 14- 18 Nisan 2014, ss.110-111