

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**





**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**ORCID :** - - -

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**

**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih :** / /

**Tezin Savunma Tarihi :** / /

**Tez Danışmanı :**

**ORCID :** - - -

**Trabzon**

## ÖNSÖZ

Yüksek Lisans Tezi olarak sunduğum “Orman Sağlığının Google Earth Engine ile İzlenmesi” başlıklı bu çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında, yüksek lisans tezi olarak gerçekleştirilmiştir.

Eğitim hayatım boyunca olumlu katkısı olan tüm çağdaş öğretmenlerime ve lisansüstü öğrenimim sırasında bilgi, tecrübe, zaman ve en önemlisi desteğini esirgemeyen saygıdeğer tez danışmanım Dr. Öğr. Üyesi Esra TUNÇ GÖRMÜŞ’e şükranlarımı sunarım.

Hayatım boyunca yanımda olan güzel aileme teşekkür eder ve şükranlarımı sunarım.

Şule YAMAN

Trabzon 2023

## TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Orman Sağlığının Google Earth Engine ile İzlenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Dr.Öğr.Üyesi Esra TUNÇ GÖRMÜŞ’ün sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 13/01/2023

Şule YAMAN

## İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ .....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET .....	VII
SUMMARY .....	VIII
ŞEKİLLER DİZİNİ .....	IX
TABLolar DİZİNİ .....	XI
SEMBOLLER DİZİNİ.....	XII
1. GENEL BİLGİLER.....	1
1.1. Ormanların Önemi.....	2
1.2. Orman Zararlıları.....	3
1.2.1. Kızılkuyruklu Kayın Tırtılı ( <i>Calliteara Pudibunda</i> ).....	4
1.3. Uzaktan Algılamanın Temel Bileşenleri .....	5
1.4. Uzaktan Algılamada Görüntü Sınıflandırma .....	6
1.4.1. Kontrollü Sınıflandırma.....	6
1.4.1.1. Piksel Tabanlı Sınıflandırma.....	7
1.4.1.2. Nesne Tabanlı Sınıflandırma .....	8
1.4.2. Kontrolsüz Sınıflandırma.....	8
1.4.3. Makine Öğrenme Algoritmaları .....	9
1.4.3.1. Rastgele Orman Algoritması (RO).....	9
1.4.3.2. Destek Vektör Makineleri (DVM) .....	10
1.5. Sınıflandırma Doğruluğu .....	11
1.6. Bulut Bilişim .....	12
1.6.1. Google Earth Engine (GEE) .....	12
1.7. Zaman Serileri Analizi.....	19
1.8. Tez Çalışmasının Amacı.....	20
2. UZAKTAN ALGILAMANIN ORMAN SAĞLIĞININ İZLENMESİNDE KULLANIMI .....	21
2.1. Orman Sağlığını İzlemede Kullanılan Bitki İndeksleri .....	26

2.1.1.	Normalleştirilmiş Fark Bitki Örtüsü Endeksi (NDVI) .....	26
2.1.2.	Gelişmiş Bitki Örtüsü İndeksi (EVI) .....	27
2.1.3.	Toprak Ayarlı Bitki İndeksi (SAVI).....	27
2.1.4.	Oran Bitki İndeksi (RVI).....	28
2.1.5.	Dönüştürülmüş Bitki İndeksi (TVI) .....	28
2.1.6.	Normalize Pigment Klorofil Oranı İndeksi (NPCRI).....	28
2.2.	Uydu Görüntüleri .....	29
2.2.1.	Landsat-8 .....	29
2.2.2.	Sentinel-2A .....	30
3.	YAPILAN ÇALIŞMALAR .....	32
3.1.	Çalışma Alanı.....	33
3.2.	Çalışmada Kullanılan Veriler ve Yazılımlar.....	34
3.3.	Görüntü Seçimi ve Ön İşleme Adımları .....	35
3.4.	Bitki İndeksleri ile Orman Sağlığı Görüntülerinin Oluşturulması .....	37
3.4.1.	NDVI Görüntülerinin Oluşturulması.....	37
3.4.2.	EVI Görüntülerinin Oluşturulması .....	38
3.4.3.	SAVI Görüntülerinin Oluşturulması .....	38
3.4.4.	RVI Görüntülerinin Oluşturulması.....	39
3.4.5.	TVI Görüntülerinin Oluşturulması .....	39
3.4.6.	NPCRI Görüntülerinin Oluşturulması .....	40
3.5.	Görüntülerin Sınıflandırılması .....	40
3.6.	Doğruluk Analizi .....	44
3.7.	Zaman Serileri Analizi ile Orman Sağlığı İzlenmesi .....	44
3.8.	Sınıflandırma Sonuçları Alan Grafikleri .....	45
4.	BULGULAR VE İRDELEME .....	46
4.1.	Tahtaköprü Mevkii Orman Sağlığının İzlenmesi.....	46
4.2.	Sınıflandırma Sonuçlarının Karşılaştırılması.....	47
4.3.	Zaman Serileri Grafiklerinin Analizi.....	52
4.4.	Sınıflandırma Sonuçları Alan Grafiklerinin Yorumlanması.....	57
5.	SONUÇLAR VE ÖNERİLER .....	60
6.	KAYNAKLAR .....	62

ÖZGEÇMİŞ

ÖZET  
ORMAN SAĞLIĞININ GOOGLE EARTH ENGINE İLE İZLENMESİ

ŞULE YAMAN

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Harita Mühendisliği Anabilim Dalı  
Danışman: Dr. Öğr. Üyesi Esra TUNÇ GÖRMÜŞ  
2023, 68 Sayfa

Bu çalışma, Kütahya-Domaniç, Bursa-İnegöl il sınırında yer alan Tahtaköprü mevkiinde bulunan kızıl kuyruklu kayın tırtılından (*Calliteara Pudibunda*) etkilenmiş ormanlık alanın Sentinel-2A ve Landsat-8 uydularına ait uydu görüntüleri ile bitki indeksleri kullanılarak orman sağlığının bulut tabanlı platformda izlenmesini anlatan yüksek lisans tez çalışmasıdır. Orman sağlığı, Sentinel-2A ve Landsat-8 uydu görüntüleri üzerinden bitki indeksleri, kontrollü sınıflandırma yöntemi kullanılarak izlenmeye çalışılmıştır. Çok sayıda bitki indeksi bulunmakta olup bu çalışmada Normalleştirilmiş Fark Bitki Örtüsü Endeksi (NDVI), Gelişmiş Bitki Örtüsü İndeksi (EVI), Toprak Ayarlı Bitki İndeksi (SAVI), Oran Bitki İndeksi (RVI), Dönüştürülmüş Bitki İndeksi (TVI) ve Normalize Pigment Klorofil Oranı İndeksi (NPCRI) indeksleri kullanılmıştır. Ayrıca rastgele orman algoritması (RO) ve destek vektör makineleri (DVM) yöntemleri, piksel ve nesne tabanlı sınıflandırma teknikleriyle ele alınmıştır. Bütün görüntü işleme, analiz, maskeleyme ve görselleştirme işlemleri Google Earth Engine (GEE) platformunda gerçekleştirilmiştir.

Çalışma alanı için kullanılan bitki indekslerinin zaman serileriyle izlenmesi sayesinde kızıl kuyruklu kayın tırtılından etkilenen alanlar dönemsel olarak tespit edilmiştir. Tespit edilen hasarlı alanlar iki farklı uydu verisi kullanılarak kontrollü sınıflandırma yardımıyla sonuçlar karşılaştırılmıştır. Karşılaştırma sonucunda piksel tabanlı DVM sınıflandırmasının Sentinel-2A uydu verileri için, nesne tabanlı RO sınıflandırmasının da Sentinel-2A uydu verileri için daha iyi sonuç verdiği tespit edilmiştir. Bu sayede, Sentinel-2A görüntüleri kullanılarak, piksel tabanlı DVM sınıflandırması ve nesne tabanlı RO sınıflandırması ile orman sağlığının başarılı bir şekilde izlenebileceği görülmüştür.

**Anahtar Kelimeler:** Orman Sağlığı, İzlenme, Sınıflandırma, Google Earth Engine

## SUMMARY

### MONITORING FOREST HEALTH WITH GOOGLE EARTH ENGINE

Şule YAMAN

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Geomatics Engineering Graduate Program  
Supervisor: Dr. Esra TUNÇ GÖRMÜŞ  
2023, 68 Pages

This study describes the monitoring of the forest area affected by the red-tailed beech caterpillar (*Calliteara pudibunda*) in Tahtaköprü, located on the provincial border of Kütahya-Domaniç, Bursa-İnegöl. Forest health of the affected area was monitored by using vegetation indices and supervised classification methods on Sentinel-2A and Landsat-8 satellite images. Among the several vegetation indices, Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI), Soil Adjusted Vegetation Index (SAVI), Ratio Vegetation Index (RVI), Transformed Vegetation Index (TVI), and Normalized Pigment Chlorophyll Ratio Index (NPCRI) indices were used in this study. In addition, random forest algorithm (RO) and support vector machines (DVM) methods are discussed with pixel and object-based classification techniques. All image processing, analysis, masking and visualization processes were performed on Google Earth Engine (GEE) platform. The areas affected by the red-tailed beech caterpillar were determined periodically by monitoring the vegetation indices used for the study area. The detected damaged areas were compared with the help of supervised classification using two different satellite data. As a result of the comparison, it was determined that pixel-based SVM classification give better results for Sentinel-2A satellite data, and object-based RO classification give better results for Sentinel-2A satellite data. In this study, it is confirmed that forest health can be successfully monitored with pixel-based SVM classification and object-based RO classification using Sentinel-2A images.

**Key Words:** Forest Health, Tracking, Classification, Google Earth Engine

## ŞEKİLLER DİZİNİ

	<b><u>Sayfa No</u></b>
Şekil 1. Türkiye orman varlığı haritası .....	3
Şekil 2. Bölgelere göre böceklerden etkilenen orman alanı .....	4
Şekil 3. <i>Calliteara Pudibunda</i> larvaları ve larvalar tarafından zarara uğrayan ağaçlar .....	5
Şekil 4. Uzaktan algılamanın temel bileşenleri.....	6
Şekil 5. Kontrollü sınıflandırma örneği .....	7
Şekil 6. Kontrolsüz sınıflandırma örneği .....	8
Şekil 7. Makine öğrenmesi algoritmaları.....	9
Şekil 8. Rastgele Orman Algoritmaları .....	10
Şekil 9. Hata matrisi .....	11
Şekil 10. Bulut bilişim ve bileşenleri .....	13
Şekil 11. Google Earth Engine arayüzü .....	14
Şekil 12. GEE veri kataloğu kümeleri .....	14
Şekil 13. Google Earth Engine Hansen Global Forest Change .....	15
Şekil 14. Google Earth Engine kod editörü paneli .....	15
Şekil 15. Google Earth Engine Script yöneticisi .....	16
Şekil 16. Google Earth Engine API Doküman yöneticisi.....	16
Şekil 17. Google Earth Engine Varlık yöneticisi .....	17
Şekil 18. Google Earth Engine Denetçi .....	17
Şekil 19. Google Earth Engine Konsol.....	18
Şekil 20. Google Earth Engine Görevler .....	18
Şekil 21. Google Earth Engine Ekran .....	19
Şekil 22. Çalışma iş akış şeması .....	33
Şekil 23. Çalışma alanı .....	34
Şekil 24. Orman zararlılarından etkilenmiş alana ait Landsat-8 uydu görüntüsü .....	36
Şekil 25. Orman zararlılarından etkilenmiş alana ait Sentinel-2A uydu görüntüsü ...	36
Şekil 26. Orman zararlılarından etkilenmiş alanın NDVI görüntüsü .....	37
Şekil 27. Orman zararlılarından etkilenmiş alanın EVI görüntüsü .....	38
Şekil 28. Orman zararlılarından etkilenmiş alanın SAVI görüntüsü .....	38
Şekil 29. Orman zararlılarından etkilenmiş alanın RVI görüntüsü.....	39

Şekil 30. Orman zararlılarından etkilenmiş alanın TVI görüntüsü .....	39
Şekil 31. Orman zararlılarından etkilenmiş alanın NPCRI görüntüsü .....	40
Şekil 32. Eğitim verisi .....	41
Şekil 33. Landsat-8 (L8) uydu verisi için RO ve DVM yöntemi ile piksel tabanlı sınıflandırma .....	42
Şekil 34. Sentinel-2A (S2) uydu verisi için RO ve DVM yöntemi ile piksel tabanlı sınıflandırma .....	43
Şekil 35. Sentinel-2A (S2) ve Landsat-8 (L8) uydu verileri için nesne tabanlı RO ile sınıflandırma .....	44
Şekil 36. Sınıflandırma sonucu alan grafiği.....	45
Şekil 37. Kızılkuyruklu kayın tırtılı ( <i>Calliteara Pudibunda</i> ) etkisi .....	46
Şekil 38. Çalışma alanına ait hava araçlarıyla elde edilmiş saha görüntüsü .....	47
Şekil 39. Landsat-8 verileriyle NDVI zaman serisi grafiği .....	52
Şekil 40. Landsat-8 verileriyle EVI zaman serisi grafiği .....	52
Şekil 41. Landsat-8 verileriyle SAVI zaman serisi grafiği.....	53
Şekil 42. Landsat-8 verileriyle RVI zaman serisi grafiği .....	53
Şekil 43. Landsat-8 verileriyle TVI zaman serisi grafiği .....	54
Şekil 44. Landsat-8 verileriyle NPCRI zaman serisi grafiği .....	54
Şekil 45. Sentinel-2A verileriyle NDVI zaman serisi grafiği.....	55
Şekil 46. Sentinel-2A verileriyle EVI zaman serisi grafiği .....	55
Şekil 47. Sentinel-2A verileriyle SAVI zaman serisi grafiği.....	55
Şekil 48. Sentinel-2A verileriyle RVI zaman serisi grafiği .....	56
Şekil 49. Sentinel-2A verileriyle TVI zaman serisi grafiği .....	56
Şekil 50. Sentinel-2A verileriyle NPCRI zaman serisi grafiği .....	56
Şekil 51. Landsat-8 için piksel tabanlı DVM ve RO sınıflandırması sonucu her bir sınıfa ait alan miktarı (2019) .....	57
Şekil 52. Sentinel-2A için piksel tabanlı DVM sınıflandırması sonucu her bir sınıfa ait alan miktarı .....	58
Şekil 53. Sentinel-2A için piksel tabanlı RO sınıflandırması sonucu her bir sınıfa ait alan miktarı.....	58

## TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Landsat 8 Collection 1 Tier 1 TOA Reflectance bant bilgisi .....	30
Tablo 2. Sentinel-2A bant bilgisi .....	31
Tablo 3. Landsat kullanılan görüntü ve özellikleri .....	35
Tablo 4. Sentinel kullanılan görüntü ve özellikleri .....	35
Tablo 5. Sınıflandırma bilgileri ve nokta sayıları .....	40
Tablo 6. RO ile tüm kombinasyonlar için genel doğruluk ve kappa katsıyısı sonuçları .....	48
Tablo 7. DVM ile tüm kombinasyonlar için genel doğruluk ve kappa katsıyısı sonuçları .....	48
Tablo 8. Landsat-8 RO ve Landsat-8 Bitki İndeksli RO sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri .....	49
Tablo 9. Landsat-8 DVM ve Landsat-8 Bitki İndeksli DVM sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri .....	50
Tablo 10. Sentinel-2A DVM ve Sentinel-2A Bitki İndeksli DVM sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri.....	50
Tablo 11. Sentinel-2A RO ve Sentinel-2A Bitki İndeksli RO sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri.....	51
Tablo 12. Nesne tabanlı Sentinel-2A ve Landsat-8 Bitki İndeksli RO sınıflandırma Sonuçları için genel doğruluk değeri .....	51

## SEMBOLLER DİZİNİ

API	: Application Programming Interface
DVM	: Destek Vektör Makineleri
EVI	: Enhanced Vegetation Index
GD	: Genel Doğruluk
GEE	: Google Earth Engine
GIS	: Geographic Information System
GNDVI	: Green Normalized Difference Vegetation Index
GPS	: Global Position System
K	: Kappa Katsayısı
L8	: Landsat-8
NDVI	: Normalized Difference Vegetation Index
NDWI	: Normalized Difference Water Index
NPCRI	: Normalized Pigment Chlorophyll Ratio Index
RDI	: Ratio Drought Index
RO	: Rastgele Orman Algoritması
RVI	: Ratio Vegetation Index
S2A	: Sentinel-2A
SAVI	: Soil Adjusted Vegetation Index
TVI	: Transformed Vegetation Index

## 1. GENEL BİLGİLER

Temiz oksijen kaynağı olan, iklim deęişikliklerinde büyük rol oynayan ve ekosistemin sürdürülebilirliğini sağlayan ormanlar, fauna ve florayı korumakta, hava kirliliğini ve doğal afetleri önlemeye yardımcı olmakta, bir çok alanda hammadde kaynağı olarak kullanılmaktadır. Ülkemizin yaklaşık %29'luk kısmını ormanlar oluşturmaktadır (OGM, 2020). Son zamanlarda yok olma ve azalma eğilimi gösteren ormanlar yangın, doğal afetler, zararlı böcekler gibi birçok nedenle tehlike altında olsa da ilk sırada zararlı böcekler yer almaktadır. Çünkü böcekler, sahip olduğu yüksek üreme hızları sebebiyle kısa bir sürede bütün bir ormana yayılarak ciddi zararlara neden olmaktadır. Orman sağlığını izlemede kamu kuruluşları, halk yardımı, gözlem-gözetleme, uçak ve helikopterlerle havadan izleme gibi birçok yöntem kullanılsa da uzaktan algılama yöntemlerinin kullanımına da son zamanlarda ilgi artmaktadır.

Daimi olarak gelişim halinde olan uzaktan algılama, yeryüzü, nesnelere, uçaklar ve uydular gibi çeşitli araçlarla fiziksel temas olmaksızın bilgi edinmeyi amaçlayan bir bilimdir. Jeoloji, sağlık, eğitim, askeri gibi bir çok alanda kullanılmasının yanı sıra orman ve ormancılık faaliyetlerindeki kullanımı da göz ardı edilemeyecek ölçüde büyüktür. Orman meşcere tipleri uydu verileriyle kısa sürede belirlenebilmekte (Uça Avcı vd., 2014), hasar ve hastalık tespitleriyle orman sağlığı izlenebilmektedir (Wang vd., 2010). Nesnelere spektral yansımaları, bitki indeksleri analizleriyle orman alanlarında sağlıklı ve sağlıklı alan tespiti yapılarak sonuç haritaları üretilmektedir (Mısır, 2016). Bu haritalar kullanılarak çeşitli böcek türlerinin verdiği zarar izlenerek gerekli tedbirler alınabilmekte ve gelecek dönemlerde tekrar etmesi önlenmektedir.

Orman zararlılarını ve sağlığını izlemek için kullanılan birçok teknik vardır. Bunlar; orta ve yüksek çözünürlüklü uydu verileri kullanılarak yapılan izleme (Erbek vd., 2005; Rullan-Silva vd., 2013), GPS yardımıyla uzaktan video konumlandırma sistemi kullanılarak yapılan izleme (Z.B. Wang vd., 2014), hava fotoğrafları, dronlar kullanılarak yapılan izleme (Sarıkaya vd., 2019), spektral analizler ve bitki örtüsü analizleri ile yapılan izlemelerdir (Anwer vd., 2019). Ancak bu yöntemlerin faydalarının yanı sıra ortak dezavantajları da vardır. Verilerin çok yer kaplaması, işlemlerin ve analizlerin hızlı gerçekleştirilememesi bu

dezavantajlardan birkaçıdır. Bu problemleri ortadan kaldırmak için Google Earth Engine gibi bulut tabanlı platformların kullanımı daha doğru bir karardır.

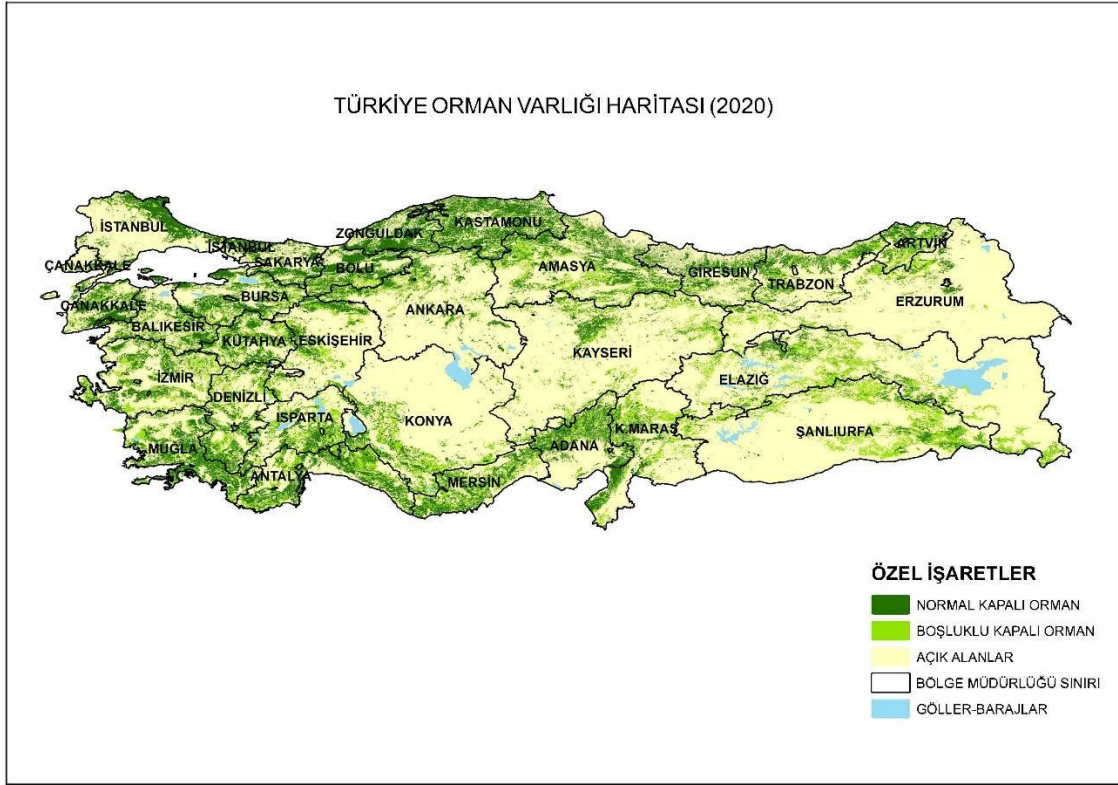
GEE, uzaktan algılanmış görüntülerin değerlendirildiği, gereksiz veri depolamasının önüne geçen, veri işlem hızını bilgisayardan ayrı tutarak hızlı analiz ve karar verme yetenekleriyle birlikte çok zengin veri setine sahip olan bulut tabanlı bir platformdur (Dereli, 2018). Sentinel, Landsat, MODIS gibi birçok farklı uyduya ait geniş tarih aralıklı uydu verilerini bünyesinde bulundurmaktadır (N. You vd., 2020).

Bunların yanı sıra orman sağlığının izlenmesinde, yaprak klorofil içeriği, bitki stresi, bitki canlılığı, toprak nem değişkenliğinin tespit edilmesinde yardımcı olan bitki indekslerinin kullanılması, orman sağlığı izlenmesini ve zararlıların tespitini kolaylaştırmaktadır.

Bu tez çalışmasında, uzaktan algılama alıcılarından olan iki farklı uydu verileri ve uzaktan algılama yöntemlerinden olan sınıflandırma yöntemleri kullanılarak bitki indeksleri ile orman zararlılarından etkilenmiş bir alanın orman sağlığı izlenmesi, tespiti ve analizi gerçekleştirilmiştir.

## 1.1. Ormanların Önemi

Ülkemizin yaklaşık %29'luk kısmını kaplayan ormanların sayısız faydası vardır. Bunlardan bazıları; doğal dengenin sürdürülebilirliğinin sağlanması, su varlığının korunması, canlı/cansız her türlü varlık için uygun ekosisteme sahip olması, havada bulunan oksijenin %56'sını üreterek canlılara kaliteli yaşam sağlaması, erozyon gibi doğal afetleri önlemesi, birçok alanda hammadde ve geçim kaynağı sağlamasıdır. Yaşadığımız ekosisteme bu kadar katkı sağlayan ormanlarımız, yangın, doğal afet, ormansızlaşma ve zararlı böcekler tarafından yok olmaktadır. Bu nedenle yeniden ağaçlandırma çalışmaları, yangın önlemleri, düzenli ve planlı kesimler, orman ve orman ürünlerinin doğru kullanılması, teknolojinin bu alanda daha faydalı kullanılması gibi çalışmalarla ormanlar koruma altına alınmalıdır. Türkiye orman varlığına ait harita Şekil 1.'de verilmiştir.



Şekil 1. Türkiye orman varlığı haritası (URL-1, 2022)

## 1.2. Orman Zararlıları

Böceklerin üreme hızlarının ve yayılımlarının çok yüksek olması sebebiyle kısa bir sürede bütün bir ormana yayılarak verdiği zararın, yangınların verdiği zarardan çok daha fazla olduğu bilinmektedir. Gıda ve Tarım Örgütü'nün 2015 yılında 62 ülkeden alınan verilerle bölgelere göre böceklerden etkilenen orman alanı miktarını belirlediği Küresel Orman Kaynakları Değerlendirme (Global Forest Resources 2020) raporuna göre sadece böceklerden etkilenen alan, 30,2 milyon hektar olarak hesaplanmıştır (Şekil 2).

Region	Data availability		Forest affected by insects	
	No. of reporting countries	% of total forest area	Area (1 000 ha)	% of forest area
Africa	6	7	436	1.0
Asia	11	47	8 743	3.0
Europe	30	95	524	0.1
North and Central America	9	98	20 381	2.7
Oceania	3	5	1.0	n.s.
South America	3	7	130	0.2
<b>WORLD</b>	<b>62</b>	<b>52</b>	<b>30 215</b>	<b>1.4</b>

Note: n.s. = not significant.


Şekil 2. Bölgelere göre böceklerden etkilenen orman alanı, 2015 (FAO,2020)

Bölge bazında bakıldığında en çok etkilenen alan 20 milyon 381 hektar alan ile Kuzey ve Orta Amerika iken en az etkilenen bölge 1000 hektar alan ile Okyanusya olmuştur.

Böcek salgınlarının temel nedeni strestir. Stres, bir bitkinin potansiyel fiziksel, metabolik değişiklikler gibi yaşamsal faaliyetlerini etkileyen bir etkidir. Toprak Ph düzeyinin çok yüksek/düşük olması, sel, kuraklık, küresel ısınma ve iklim değişikliği gibi atmosferik kirlenme olayları veya aşırı düşük/yüksek sıcaklık hepsi stres etkenidir. Bu etkenler sonucu bitkinin değişen besinsel niteliği böcekler için caziptir (URL-2, 2022).

### 1.2.1. Kızıl Kuyruklu Kayın Tırtılı (*Calliteara Pudibunda*)

Avrupa'da kayın zararlısı olarak bilinen kızıl kuyruklu kayın tırtılı (*Calliteara Pudibunda*), bazı otsu bitkilerle beraber meşe, söğüt, huş, dişbudak, gürgen, akçaağaç gibi yapraklı orman ağaçları ile de beslenebilmektedir . Bunun sonucunda da ağaçlar tamamen yapraksız kalıp gelişimleri engellenmektedir (Sarıkaya vd., 2021). Kızıl kuyruklu kayın tırtıl larvalarının iyice olgunlaşarak irileştiği eylül ve ekim aylarında kayın yaprak yiyimi yaptığı bu nedenle de ağaçların yapraksız kalmasına ve kurumuş gibi gözükmesine sebep olduğu bilinmektedir (URL-3, 2022).




Şekil 3. *Calliteara Pudibunda* larvaları ve larvalar tarafından zarara uğrayan ağaçlar (Sarı vd., 2021)

Ülkemiz kayın ormanlarında ekonomik zarara yol açmış ve epidemiyeye neden olan zararlı türlere çok sık rastlanılmasa da Göktürk ve Aksu (2005), Artvin yöresindeki kızılığaç ve huş ağaçları üzerinde *Calliteara pudibunda* zararlısını bildirmiştir. Aynı zararlıya 2018 ve 2019 yıllarında İnegöl (Bursa) kayın ormanlarında rastlanmış ve ciddi epidemiyeye neden olmuştur.

### 1.3. Uzaktan Algılamanın Temel Bileşenleri

Uzaktan algılama, yeryüzü, nesnelere, uçaklar ve uydular gibi çeşitli araçlarla fiziksel temas olmaksızın bilgi edinmeyi amaçlayan bir bilim dalıdır. Veri elde etme ve veri işleme olmak üzere 2 aşamadan oluşan uzaktan algılamanın gerçekleştirilmesi için 7 adet şartın gerçekleşmesi gerekmektedir. Bu şartlardan ilki hedefi aydınlatan bir enerji kaynağına sahip olmaktır. İkincisi enerjinin, kaynak ile hedef arasında atmosferde etkileşime girmesi ve oluşan ışıdır. Üçüncü şart ise atmosfer sayesinde hedefe ulaşan enerjinin hedefle etkileşime girmesidir. Dördüncü şart, hedefle etkileşime giren enerjinin kaydedilmesi için gerekli olan algılayıcıdır. Beşinci şart, algılayıcı tarafından kaydedilen enerjinin, elektronik biçimde işlenerek basılı bir görüntü oluşturmak için bir alıcı ve işleme istasyonuna ihtiyaç vardır. Altıncı şart ise işlenen görüntünün, aydınlatılan hedefin hakkında yorum ve analiz yapmaktır. Yedinci ve son şart ise elde edilen görüntüden analiz edilen bilgilerin başka bilgiler elde etmek için kullanılması ve uygulanmasıdır (Şentürk, 2020).

Şekil 4.'te bu anlatılanlar görsel olarak sunulmuştur (URL-4, 2022).



Şekil 4. Uzaktan algılamamın temel bileşenleri (A: Enerji kaynağı/ışınım B: Işınım/radyasyon ve atmosfer C: Hedef ve interaksiyon D: Sensör tarafından kaydedilen enerji E: Transmisyon, alma ve işleme F: Yorumlama ve analiz G: Uygulama )


#### 1.4. Uzaktan Algılamada Görüntü Sınıflandırma

Birçok bilim dalında kullanılan sınıflandırma bir karar verme yöntemidir. Asıl amaç, görüntüdeki pikselleri arazideki karşılık geldikleri sınıflara otomatik olarak atamaktır. Uzaktan algılama verilerini sınıflandırmak için birçok farklı yöntem vardır. Bununla beraber sınıflandırma kontrollü ve kontrolsüz olmak üzere 2 ana gruba ayrılmaktadır (Hasmedi vd., 2009).

##### 1.4.1. Kontrollü Sınıflandırma

Kontrollü sınıflandırma, kullanıcının kontrolünde olan sınıflandırma yöntemidir. Kullanıcı, görüntüde hangi sınıfların dikkate alınacağını ya da hangi sınıfların elde edileceğini örnek sınıflarla belirlemektedir (Sabuncu ve Sunar, 2017) . Bu örnek sınıflara eğitim kümesi adı verilmektedir. Spektral ayırt edilebilirliği incelenen bölgeler, eğitim kümesindeki hücrelerin özneliliklerine bağlı olarak sınıflara ayrıştırılmaktadır. Kısaca,

kontrollü sınıflandırma yöntemi eğitim aşaması, sınıflandırma aşaması ve çıktı aşaması olmak üzere üç adımdan oluşmaktadır (Karabacak ve Yılmaz, 2012).



Şekil 5. Kontrollü sınıflandırma örneği (URL-5, 2022)

Çalışmada kontrollü sınıflandırma yöntemleri ile gerçekleştirilen sınıflandırmalar, piksel tabanlı ve nesne tabanlı tekniklerle ele alınarak sonuçlar karşılaştırılmıştır.

#### 1.4.1.1. Piksel Tabanlı Sınıflandırma

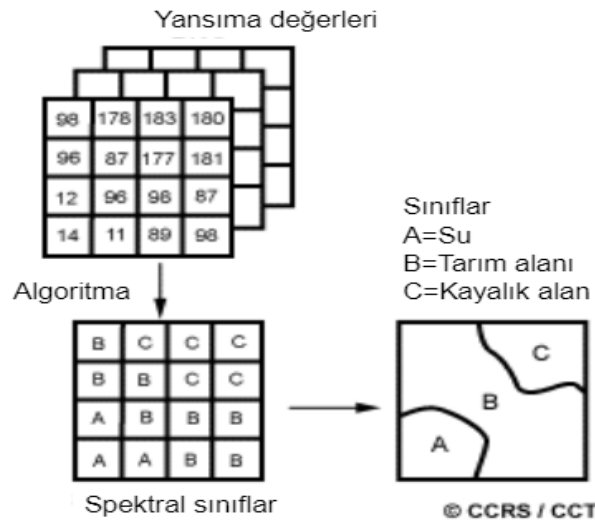
Görüntü sınıflandırma işlemlerinde günümüze kadar piksel tabanlı sınıflandırma yöntemi ağırlıklı olarak kullanılmıştır. Piksel tabanlı sınıflandırma, görüntü üzerindeki pikselleri renk değerine ve piksellerin komşuluk ilişkilerine dayalı olarak sınıflandırma işlemini gerçekleştiren yöntemdir. Özetle belirlenen eğitim verilerini, spektral özelliklerine göre tanımladıktan sonra her bir pikseli hesaplanan olasılık değerine göre en çok benzer olduğu ilgili sınıfa atamaktadır (Özen, 2013). Piksel tabanlı sınıflandırma sadece pikselin gri değerine dayalı bir çıkarım yapmaktadır (Sabuncu ve Sunar, 2017).

### 1.4.1.2. Nesne Tabanlı Sınıflandırma

Son yıllarda uydu verilerinin, hava fotoğraflarının mekansal çözünürlüklerinin artması, zengin bilgi içeriklerine sahip olması ve bunlara kıyasla sınıflandırmalardan istenilen verimin geleneksel piksel tabanlı yöntemlerle elde edilememesinden dolayı nesne tabanlı sınıflandırma yöntemi piksel tabanlı sınıflandırma yönteminin yerini almaktadır (Navulur, 2007). Nesne tabanlı sınıflandırma, piksel tabanlı sınıflandırmanın aksine pikselleri tekil değerlerine göre değil spektral özelliklerine göre gruplandırılarak görüntü objeleri oluşturmakta ve pikseller yerine objeleri sınıflandırmaktadır (Blaschke 2010; Myint vd., 2011). Bu sayede sayısız piksel yerine pikselleri temsil eden objelerin yapı, doku, spektral bilgiler ve büyüklükleri dikkate alınarak sınıflandırma yapılmaktadır (Sabuncu ve Sunar, 2017).

### 1.4.2. Kontrolsüz Sınıflandırma

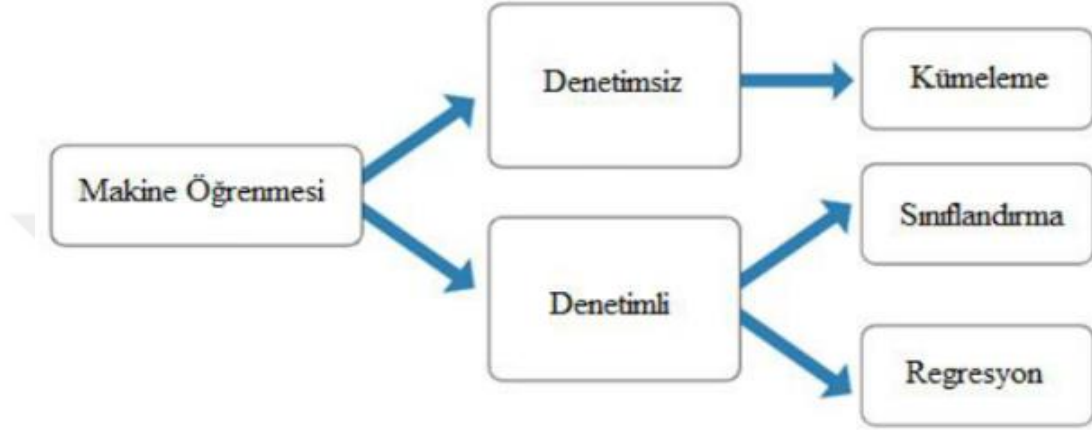
Kontrollü sınıflandırmanın aksine kullanıcı müdahalesinin olmadığı sınıflandırma yöntemidir. Sınıflar, belirli algoritmalar yardımıyla görüntüdeki piksellerin otomatik olarak sınıflandırılmasıyla elde edilmektedir. Pikseller spektral özelliklerine göre kümelenmektedir (Sabuncu ve Sunar, 2017). Kullanıcı sadece sınıf sayısını, iterasyon sayısını ve yakınsama eşik değerini belirlemektedir (URL-5, 2022).



Şekil 6. Kontrolsüz sınıflandırma örneği (URL-5, 2022)

### 1.4.3. Makine Öğrenme Algoritmaları

Makine öğrenmesi, verilerden modeller oluşturan yöntemler bütünüdür. Algoritmalar, veri setini modele dönüştüren motorlardır. Kontrollü, kontrolsüz, sınıflandırma, regresyon ve kümeleme algoritmalarından hangisinin en iyi şekilde çalıştığı verinin türüne, kaynaklarına, niteliğine ve istenilen sonuca göre değişmektedir.



Şekil 7. Makine öğrenmesi algoritmaları (URL-6, 2022)


Doğrusal regresyondan derin sinir ağlarına sayısız makine öğrenme algoritması vardır. Ancak, Linear regression, Logistic regression, Karar ağaçları, Naive Bayes, K-En yakın komşuluk, Destek Vektör Makinesi (DVM) ve Rastgele Orman Algoritması (RO) en yaygın olarak kullanılan algoritmalarlardır. Çalışma kapsamında destek vektör makineleri ve rastgele orman algoritmaları seçilmiştir.

#### 1.4.3.1. Rastgele Orman Algoritması (RO)

Rastgele orman algoritmaları, kontrollü sınıflandırma algoritmasından olup iki aşamalıdır. Öncelikle basit bir algoritma yardımıyla rastgele orman oluşturulur daha sonra bu ormanlar üzerinden sınıflandırma yapılmaktadır. (Yılmaz vd., 2019; Yaman vd., 2022). İçerisinde bulunan birçok sınıflandırma ağacı sayesinde doğru sınıflandırma değerini arttıran bir yöntemdir (Özlüer Başer vd., 2021).

Rastgele orman algoritması, ağaç sayısı (N) ve ağaç yapısının oluşturulması için her düğümde kullanılacak değişken sayısı olan m parametrelerini kullanır. Seçilen

parametrelerin 2/3'ü eğitim verisi, 1/3'ü test verisi olarak belirlenir. Her ağaç için bootstrap tekniği ile önyüklemeli örneklem oluşturulur. Her bir örneklem için ağaç gelişimi başlatılır ve her düğümde tüm değişkenler arasından  $m$  sayıda rastgele seçilen değişkenler kullanılarak en iyi dallanmalar belirlenir. Bu işlemi gerçekleştirebilmek için CART (Classification and Regression Tree) algoritması kullanılır. CART algoritması ile karar ağaçları oluşturulur ve karar ağaçları her bir pikseli sınıflandırır. Görüntüdeki tüm pikseller için her bir karar ağacı ağırlığına göre sınıflandırma oyu kullanır. Bir piksel için en çok oyu alan sınıf o piksele atanır ve sınıflandırma işlemi gerçekleştirilmiş olur (Erdem vd., 2018).



Şekil 8. Rastgele orman algoritması (Öztürk,2022)

#### 1.4.3.2. Destek Vektör Makineleri (DVM)

Destek vektör makineleri, istatistiksel öğrenme tabanlı bir kontrollü sınıflandırma algoritmasıdır (Kavzoğlu vd., 2010). DVM'nin geleneksel yöntemlere göre daha başarılı sonuç verdiği bilinmektedir (Aghlmand vd., 2021; P.Mantero vd., 2005; G. Mountrakis vd., 2011). Sınıflandırma problemlerinde kullanılan DVM algoritması regresyon problemlerinde de kullanılmaktadır. Regresyon modelinin temeli, eğitim verilerini mümkün olduğunca gerçeğe yakın bir şekilde sunan ve istatistiksel öğrenme teorisine uyan doğrusal ayırıcı fonksiyona dayanmaktadır. Sınıflandırma esnasında, sınıfları birbirinden çok iyi ayırabilen hiper-düzlemi kullanılmaktadır (Cruz vd. 2020; Yaman vd.,2022). DVM'nin en ilginç özelliği veri seti üzerinde ortalama hata karesini minimize etmesinden ziyade istatistiksel öğrenme teorisindeki yapısal risk minimizasyonu niteliğindedir (Yakut vd., 2014).

### 1.5. Sınıflandırma Doğruluğu

Birçok alanda olduğu gibi uzaktan algılamada da sonuç ürünlerin değerlendirilmesi için doğruluk değerlendirmesi önem arz etmektedir. Değerlendirmedeki amaç, sonuç ürünün sınıflandırma kalitesi ve kullanıcı üzerindeki güveni artırmaktır (Foody, 2001; Hasmadi ve ark., 2009). Uzaktan algılamada sınıflandırma doğruluğu, piksel için seçilen “sınıf etiketi” ile hava fotoğrafları, haritalar, planlar üzerinden doğrudan veya dolaylı olarak gözlenebilen “gerçek sınıf” arasındaki uygunluğu göstermektedir (Özen, 2013). Ancak bazen sınıflandırılmış ve referans veriler arasında sınıflandırma anlaşmazlıklarından dolayı hatalar ortaya çıkarabilmektedir. Bu nedenle doğruluk değerlendirmelerinde hata matrisi (confussion matrix) adı verilen ölçüt kullanılmaktadır. Hata matrisleri referans veriler ile sınıflandırılmış veriler arasındaki ilişkiyi karşılaştırmaktadır. Referans veriler rastgele seçilmektedir (Congalton, 1991). Sınıflandırmanın doğruluğunu belirlemekte referans veri sayısı çok önemli olup bir sınıfın doğruluk ortalamasını +%5 ve -%5 aralığında tahmin edebilmek için 250’den fazla referans veriye ihtiyaç duyulduğu bilinmektedir (Congalton,1991).

**Örnekleme veri seti**

Sınıf →	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	·	·	C <sub>n</sub>	Toplam
C <sub>1</sub>	Σ						Σ
C <sub>2</sub>		Σ					Σ
C <sub>3</sub>			Σ				Σ
·				Σ			Σ
·					Σ		Σ
C <sub>n</sub>						Σ	Σ
Toplam	Σ	Σ	Σ	Σ	Σ	Σ	Σ

Doğru olarak sınıflandırılmış pikseller  
 Doğru sınıflandırılmış toplam piksel sayısı

Şekil 9. Hata matrisi (URL-7, 2022)

Hata matrisinin, genel sınıflandırma doğruluğu, üreticinin doğruluğu ve kullanıcının doğruluğu olmak üzere üç temel ana ölçütü vardır (Şentürk, 2020). Genel sınıflandırma doğruluğu, sınıflandırılan verinin tümünden ne kadarlık bir alanın doğru olarak sınıflandırıldığı ölçütüdür. Hata matrisindeki, köşegen üzerindeki doğru sınıflandırılmış piksel sayısının, referans piksellerin toplam sayısına bölünmesiyle elde edilmektedir. Köşegen dışı elemanlar ise “ihmal hatası” olarak değerlendirilmektedir (Özen, 2013; Şentürk, 2020).


Üreticinin doğruluğu ise her sınıf için hesaplanan piksel sayısının, bu sınıf için kullanılmış olan toplam referans veri piksel sayısına bölünmesiyle elde edilmektedir. Bu doğrulukla, üreticinin kendisi tarafından sınıflandırmayı ne kadar doğru gerçekleştirdiği test edilmektedir (Özen, 2013; Şentürk, 2020). Kullanıcının doğruluğu da üretici doğruluğu gibi her sınıf için hesaplanmakta olup sınıflandırılan veri ile gerçekte o verinin ne kadar doğru temsil ettiğini göstermektedir (Özen, 2013).

Sınıflandırma doğruluğu ve güvenilirliği hakkında bilgi veren bir diğer ölçüt ise Kappa katsayısıdır. Cohen (1960) tarafından geliştirilen, hata matrisindeki tüm elemanları kullanarak sınıflandırma verilerini referans verilerle karşılaştırmaktadır. Kappa katsayısı her sınıf için hesaplanmaktadır. K kappa katsayısı 0 ila 1 arasında değer alırken istenilen ideal değer 1’dir (Çetinkaya vd., 2007).

Sınıflandırma doğruluklarında duyarlılık (recall), kesinlik (precision), F-score gibi güncel doğruluk metrikleri de kullanılmaktadır. F-score duyarlılık ve kesinlik değerlerinin harmonik ortalamasından oluşmaktadır. Bu nedenle de doğruluk değerinin başarılı bir göstergesidir.

## 1.6. Bulut Bilişim

Sürekli gelişen ve gelişmekte olan teknoloji, internet ve yazılımlar sayesinde kullanıcılar kısıtlı hizmet veren, maliyeti yüksek klasik bilgi teknolojileri yerine, depolamada büyük yerler kaplamayan, ekonomik ve ulaşımı kolay bulut bilişim teknolojilerini tercih etmektedir. Bulut bilişim, internet üzerinden başka sunuculara bağlanarak bir yazılım veya depolamaya ihtiyaç duymaksızın bilgisayar, tablet veya akıllı mobil cihazlar üzerinden hizmet veren bir modeldir (Kavzoğlu vd., 2012).

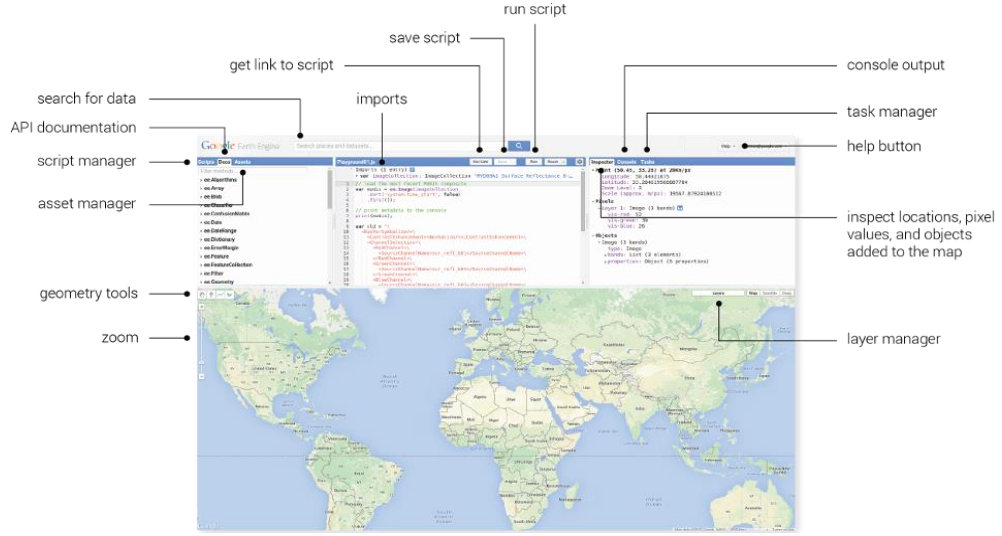


Şekil 10. Bulut bilişim ve bileşenleri (Kavzoğlu vd., 2012)

Yaygınlaşan bulut bilişim teknolojileriyle bulut tabanlı programlara olan ilgi de artmaktadır. ArcGIS Server, Google Maps API, GIS Cloud, Google Earth Engine bulut tabanlı platformlardan bazılarıdır. Çalışmadaki analizler, işlemler, çalışmalar, GEE üzerinden gerçekleştirilmiştir.

### 1.6.1. Google Earth Engine (GEE)

Her geçen gün gelişen ve değişen teknolojiyi, insanoğlunun yakından takip etmesi ve ayak uydurması zorunludur. Google Earth Engine, JavaScript API için web tabanlı bir geliştirme ortamı olan yeni bir teknoloji platformudur. Kullanıcılara hazır kod kullanma ve kod yazma paneli imkanı sunarak bu platformda gerçekleştirilen tüm işlemleri depolama ihtiyacı olmaksızın, kısa sürede, maliyetsiz gerçekleştirmektedir ( Şekil 11.). Sahip olduğu geniş aralıklı, zengin veri seti sayesinde verilerini açık kaynaklı sunarak tüm kullanıcılara hızlı ve ücretsiz veri erişimi sağlamaktadır. Son 40 yıla ait küresel ölçekli birçok veriye sahip olduğu bilinmektedir (Aghlmand vd. 2021). Platformu kullanmak için bir Google hesabına sahip olmak yeterlidir. Bu hesap ile sisteme giriş yapılarak GEE'nin sunduğu tüm imkanlardan ücretsiz şekilde faydalanılmaktadır. Ayrıca gerçekleştirilen çalışmalar, platformun sağladığı URL aracılığıyla diğer platform kullanıcıları ile paylaşılabilir.



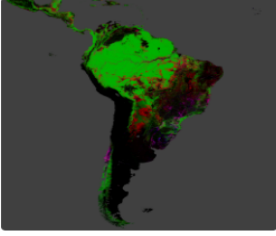
Şekil 11. Google Earth Engine arayüzü (URL-8, 2022)

GEE, Landsat-8, Sentinel 1,2,3 ve 5, MODIS gibi uydu görüntüleriyle beraber ekolojik-iklimsel, arazi yüzey sıcaklığı ve orman değişikliği gibi coğrafi referanslı çok zengin veri kataloğuna sahiptir. Şekil 12.'de GEE'nin sahip olduğu veri kataloglarından bazıları gösterilmiştir. Bu veri kataloğunda bulunan "Hansen Global Forest Change" kataloğu sayesinde orman varlığının kaybı ve kazancı izlenmesi de yapılabilmektedir (Şekil 13.). Hansen küresel orman değişikliği veri seti ile 2000-2014 yılları arası Landsat-8 uydu görüntülerinin kullanıldığı zaman serileri yardımıyla küresel orman değişikliği tespit edilebilmektedir (Miller, 2016).



Şekil 12. GEE veri kataloğu kümeleri (Göral, 2022)

**Hansen Global Forest Change v1.9 (2000-2021)**



DESCRIPTION BANDS TERMS OF USE CITATIONS DOIS

Results from time-series analysis of Landsat images in characterizing global forest extent and change.

The 'first' and 'last' bands are reference multispectral imagery from the first and last available years for Landsat spectral bands 3, 4, 5, and 7. Reference composite imagery represents median observations from a set of quality-assessed growing-season observations for each of these bands.

Please see the [User Notes](#) for this Version 1.9 update, as well as the associated journal article: Hansen, Potapov, Moore, Hancher et al. "High-resolution global maps of 21st-century forest cover change." *Science* 342.6160 (2013): 850-853.

Dataset Availability  
2000-01-01T00:00:00 - 2021-01-01T00:00:00

Dataset Provider  
[Hansen/UMD/Google/USGS/NASA](#)

Collection Snippet

```
ee.Image("UMD/hansen/global_forest_change_2021_v1_9")
```

[See example](#)

CLOSE IMPORT

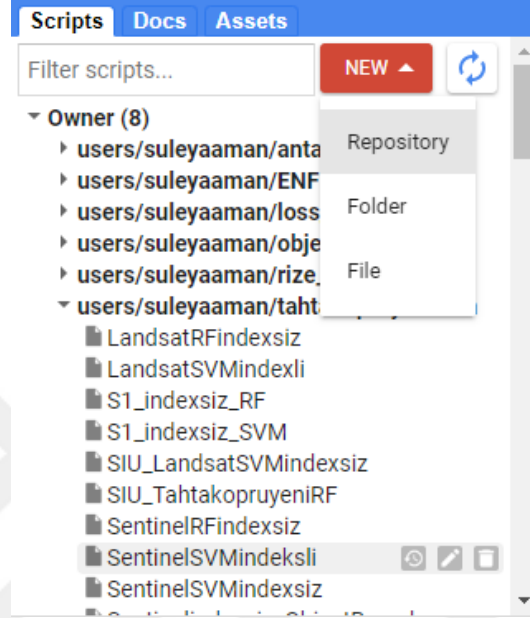
Şekil 13. Google Earth Engine Hansen Global Forest Change (URL-8, 2022)

GEE üzerinden yangın analizleri, orman sağlığı ve zararlıları izlenmesi, değişim analizleri, spektral yansıma grafikleri, nesne tabanlı ve piksel tabanlı sınıflandırmalar, makine öğrenmesi algoritmaları ile işlemler, zaman serileri analizleri ve daha birçok işlem gerçekleştirilebilmektedir. Tüm bu işlemler GEE'nin kod editörü panelinde gerçekleştirilmektedir (Şekil 14.).

```
SentinelSVMindeksli *
Get Link Save Run Reset Apps
58 var palette = [ grey , white , black ,];
59
60 var ndviVis = {min:0.5, max:1, palette:palette}
61 Map.addLayer(ndviComposite, ndviVis, 'ndvi')
62
63 // Display a time-series chart
64 var chart = ui.Chart.image.series({
65   imageCollection: withNdvi.select('ndvi'),
66   region: geometry,
67   reducer: ee.Reducer.mean(),
68   scale: 10
69 }).setOptions({
70   trendlines: {
71     0: {
72       color: 'CC0000',
73       type: 'linear',
74       showR2: true,
75       visibleInLegend: true,
76     },
77   },
78   lineWidth: 1,
79   pointSize: 1,
80   title: 'NDVI Time Series',
81   interpolateNulls: true,
82   vAxis: {title: 'NDVI'},
83   hAxis: {title: '', format: 'YYYY-MM'}
84 })
85 print(chart);
86 // Calculate Soil-adjusted Vegetation Index (SAVI)
```

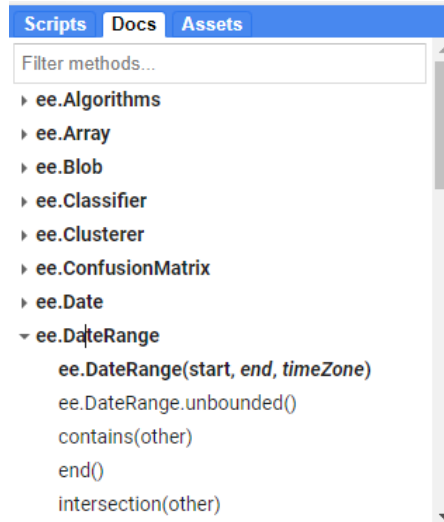
Şekil 14. Google Earth Engine kod editörü paneli

Kod editörü panelinde kod yazma işlemi yapıldıktan sonra “Save” butonu ile yapılan işlemler yönetim panelindeki script yöneticisine kayıt edilmektedir. Script yöneticisine kaydedilen çalışmalar daha sonra buradan import edilebilmekte ve kullanılabilir. Bu alan üzerinden yeni klasörler, dosyalar da oluşturulmaktadır (Şekil 15.).



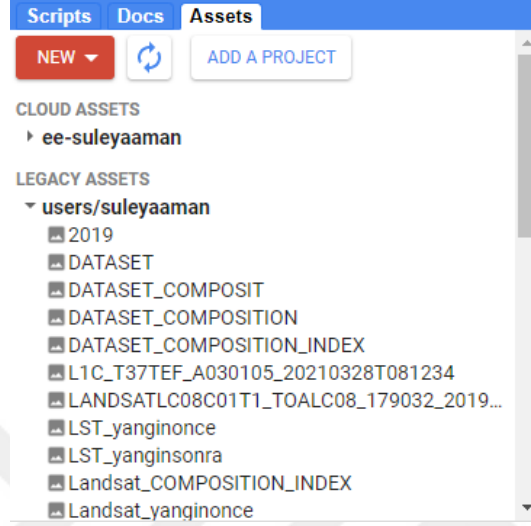
Şekil 15. Google Earth Engine Script yöneticisi

Yönetim panelinde bulunan bir diğer alan ise GEE'nin kullanıcılara sunduğu kodların çalışma mantığını, girdilerini ve çıktılarını ipuçları ile gösteren API Doküman kısmı yani Docs yöneticisidir (Şekil 16.).



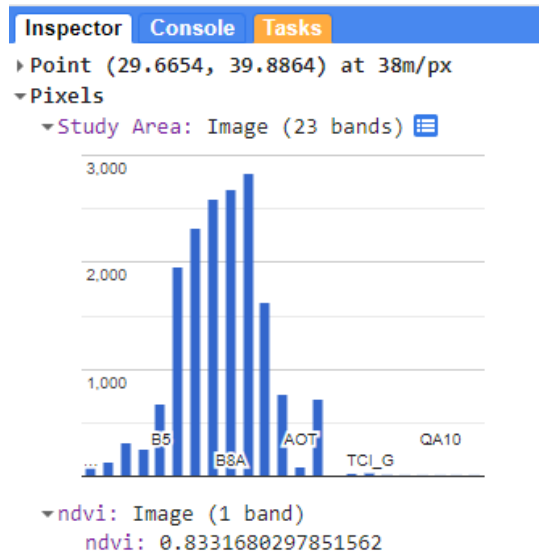
Şekil 16. Google Earth Engine API Doküman yöneticisi

GEE'nin sahip olduğu veri seti bazen kullanıcılara yetersiz gelmekte ve istedikleri verileri bulamamaktadırlar. Bu nedenle GEE isteyen kullanıcılara raster ve vektör veri yükleyebilecekleri bir alan da sunmuştur. Bu alan Şekil 17'de gösterilen varlık yöneticisi alanıdır.



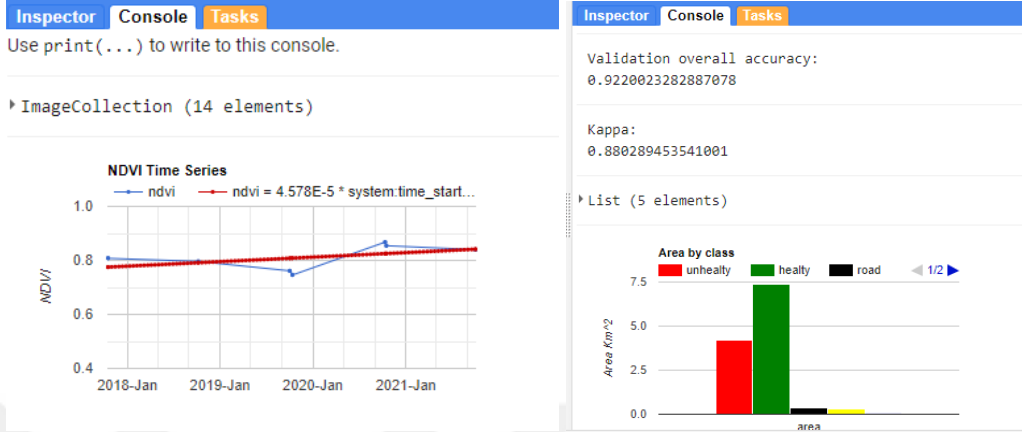
Şekil 17. Google Earth Engine Varlık yöneticisi

GEE'nin yönetim panelinde ve kod editörü panelinde gerçekleştirilen işlemlerin sonuçları arayüzün sağ tarafında bulunan konsol panelinde gösterilmektedir. Konsol panelinde bulunan Denetçi (Inspector) alanında ekranda gösterilen görüntülerin konumsal bilgileri, bant bilgileri ve piksel değerleri gibi detaylı bilgiler bulunmaktadır (Şekil 18.).



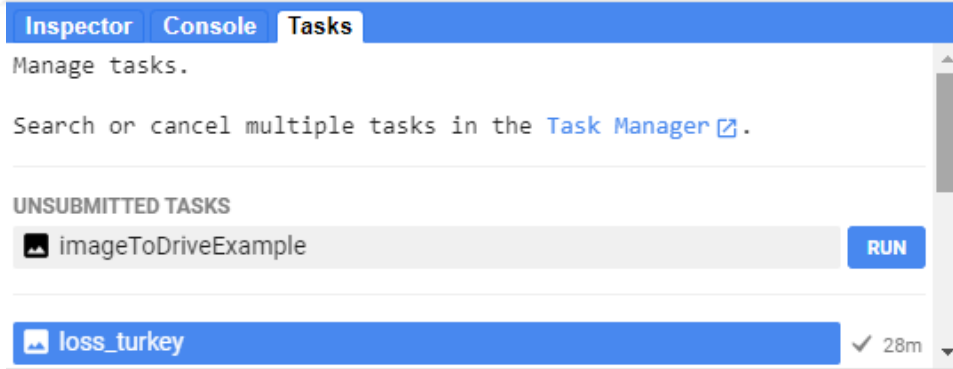
Şekil 18. Google Earth Engine Denetçi (Inspector)

Konsol alanında ise kod editöründe yazılan kodların print() komutu ile yazdırılan doğruluk değeri, zaman serisi grafiği, alansal grafikler, sınıflandırma sonuçları gibi bilgiler bulunmaktadır (Şekil 19.).



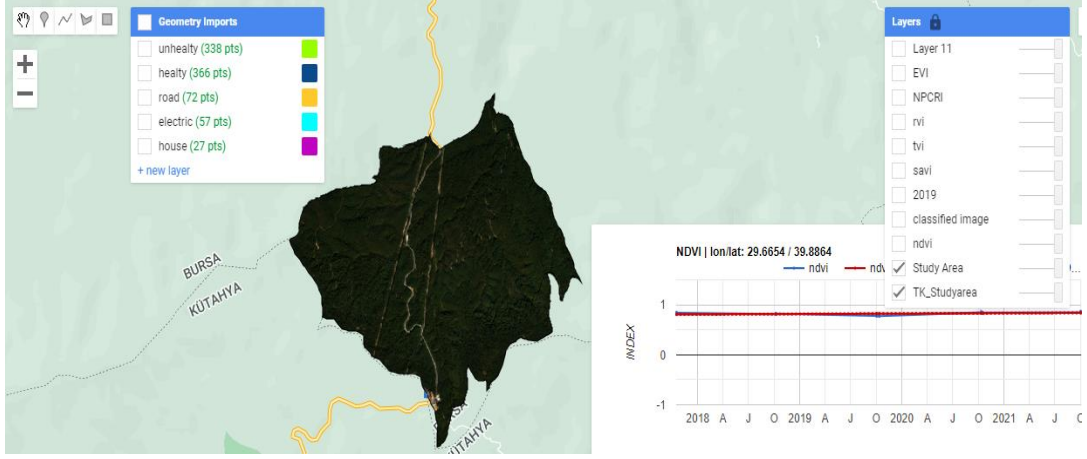
Şekil 19. Google Eath Engine Konsol

Konsol panelinde bulunan bir diğer alan ise Şekil 20.'de gösterilen ekrana basılan görüntülerin çözünürlüklerinin ayarlanarak Google Drive veya platformda bulunan yönetim paneli gibi istenilen yere dışarı aktarılabilirdiği Görevler (Tasks) alanıdır.



Şekil 20. Google Earth Engine Görevler (Tasks)

Kod editörü panelinde gerçekleştirilen işlemler sonucu Map.addLayer() komutu ile ekrana bastırılan ve Katmanlar (Layers) kısmına eklenen görüntülere dair örnek Şekil 21.'de verilmiştir. Katmanlar (Layer) panelinden görüntülerin renkleri ayarlanabilmekte, geometri aracı ile görüntü üzerinden nokta, çizgi, poligon çizim araçları kullanılarak veriler oluşturulmaktadır.



Şekil 21. Google Earth Engine ekran

### 1.7. Zaman Serileri Analizi

Bir olayın gözlem değerlerinin zamana göre sıralanmasıyla oluşturulan serilere “zaman serileri” denir (Özer vd., 2013). Zaman serileri ile geçmiş olay izlenmesi ve gelecek olay tahmini yapılabilmektedir. Zaman serisi grafiklerinin analizi ve yorumlanmasında trend (eğilim) ve seasonality (sezonsallık) en önemli kavramlardır. Trend, veri setindeki uzun vadeli artış ya da azalışa göre eğilim yönünü gösteren çizgidir. Her zaman doğrusal olmak zorunda değildir. Bazı trendler artan eğilim gösterirken birden azalan eğilime dönüşebilmektedir. Bu veri setine ait trend çizgisi “yön değiştiren trend” olarak adlandırılmaktadır. Sezonsallık ise zaman serilerinin olmazsa olmaz kavramıdır. Bu nedenle haftanın günleri ya da yılın haftaları gibi döngü oluşturan periyotlarla verilerin zamana göre sıralanmasına sezonsallık denmektedir. Buna bağlı olarak zaman ve veri seti gibi iki değişken arasındaki ilişkiyi veya bir değişkenin diğer değişkenlerle olan ilişkisini test etmek amacıyla kullanılan korelasyon analizi zaman serilerindeki istatistiksel yöntemlerdendir. Korelasyon analizi sonucunda değişkenler arasında doğrusal ilişki olup olmadığı ve korelasyon kat sayısı olan “r” değeri hesaplanarak sonuçlar yorumlanır (Selim, 2018). Korelasyon katsayısı 0-1 arası değer almakta olup r değerleri ve yorumları şu şekildedir;

0,00 – 0,25 : Çok Zayıf

0,26 – 0,49 : Zayıf

0,50 – 0,69 : Orta

0,70 – 0,89 : Yüksek

0,90 – 1,00 : Çok Yüksek

Ayrıca literatürde birçok uzaktan algılama ve zaman serilerinin birlikte kullanıldığı çalışmalar vardır. Bunlardan biri Ogata ve Kirimoto (2002)'nin Dalian bölgesi için Landsat-TM ve ETM+ verilerini kullanarak zaman serileri analizi ile arazi değişikliğini izledikleri çalışmadır. Bir diğeri ise Neteler (2004)'in MODIS uydu verileriyle aylık yüzey sıcaklığı zaman serisi analizini kullanarak gerçekleştirdiği epidemiyoloji modellemesidir. Benzer şekilde, Acker vd., (2009), yaptığı çalışmada geniş görüş alanı sensörü ile Kongo nehri kıyısındaki alanların, klorofil zaman serileri analizini gerçekleştirerek nehir etkisinin klorofil miktarı üzerindeki etkisini araştırmıştır. Piwowar ve Ledrew (2010) ise iklim değişikliği izlemeleri için zaman serileri analizini kullanmıştır.

### **1.8. Tez Çalışmasının Amacı**

Orman sağlığı izlemeleri, gözlem ve gözetlemelerle, helikopter gibi hava araçları ile, halk ve kamu kuruluşları yardımı ile sıklıkla yapılmaktadır. Bunların yanı sıra bulut tabanlı platformlarda gerçekleştirilen uzaktan algılama yöntemleri ile orman sağlığının izlenmesi diğer yöntemlere göre yeni sayılabilecek yöntemlerdendir. Bu yöntemin diğer yöntemlere göre avantajı ise zengin ve geniş tarih aralıklı veri setlerine hızlı, kolay ve düşük maliyetle ulaşılabilir olması ve ayrıca büyük depolama alanlarına ihtiyaç duyulmamasıdır.

Hazırlanan bu tez çalışması, bulut tabanlı platform olan GEE' de Sentinel-2A ve Landsat-8 uydu görüntüleri ve bitki indeksleri kullanarak orman sağlığının izlenmesini amaçlamaktadır. Bu nedenle orman zararlılarından etkilenmiş çalışma alanı, çeşitli kontrollü sınıflandırma yöntemleriyle izlenmiş ve zararlılardan etkilenen alanların tespiti ve analizi yapılmıştır. Tahrip olmuş alanlar, zamanla ilişkilendirilerek tarihsel gelişimi izlenmiş ve yorumlanmıştır. Hangi uydu görüntüsünün ve hangi sınıflandırma yönteminin orman sağlığını izlemekte daha iyi olduğu karşılaştırmalarla ortaya konulmuştur.

Bu tez çalışması 5 bölümden oluşmaktadır. Birinci bölümde, genel bilgiler verilerek tez çalışmasına giriş yapılmıştır. İkinci bölümde orman sağlığı izlenmesinde uzaktan algılamanın kullanımına dair bilgiler verilmiştir. Üçüncü bölümde ise tez kapsamında yapılan çalışmalar hakkında bilgiler bulunmaktadır. Dördüncü bölümde çalışma kapsamında elde edilen bulgular değerlendirilerek irdelemeler yapılmıştır. Beşinci bölümde ise tez çalışmasında ulaşılan sonuçlar ve yapılan öneriler bulunmaktadır.

## 2. UZAKTAN ALGILAMANIN ORMAN SAĞLIĞININ İZLENMESİNDE KULLANIMI

Uzaktan algılama, eğitim, askeri, jeoloji, madencilik, tarım, şehircilik, ormancılık gibi birçok alanla entegre edilebilen bilim dallarından birisidir. Ormancılıkta kullanımı incelendiğinde orman meşcere tiplerinin belirlenmesine, orman yangınlarının tespiti, analizi ve izlenmesine, ormansızlaşmaya, böcek istilalarının ormanlar üzerindeki etkilerinin gözlenmesine yardımcı olduğu görülmüştür. Bu konuyla ilgili literatürde, dünyada ve Türkiye’de bir çok çalışmaya rastlanmış ve çalışmalardan bazıları şu şekilde özetlenebilir;

Z B Wang vd., (2014) çalışmalarında orman zararlılarının tespitini ve izlenmesini hızlı bir şekilde gerçekleştirebilmek ve ayrıca insan gücünü azaltmak amacıyla bir araştırma modeli ortaya koymayı hedeflemişlerdir. Araştırma modelini destekleyebilmek için bir konumlandırma algoritması ve konumlandırma sistemi oluşturulmuştur. Konumlandırma sistemi olarak PDA’nın sahip olduğu GPS ile uzaktan video konumlandırma sistemi kullanılmıştır. Kuruyan arazileri, ağaç taçlarının değişmesine neden olan zararlıları tespit etmekte oldukça iyi olan bu video sistemi ile araziler hızlıca taranabilmekte ve önemli ölçüde insan gücü azaltılabilmektedir. PTZ kameralarına ve DEM verisine dayalı olan konumlandırma algoritması, hastalıklı alanların tematik haritasını üretebilen 2D CBS alt sistemi, konumları görsel hale getirebilen 3D CBS alt sistemi, video kontrol alt sistemi ve hastalıklı alan konumlandırma alt sisteminden oluşmaktadır. Çalışma sonucunda araştırma modelinin orman alanları için pratik uygulamada orman hastalıklarını ve zararlılarını gözlemleyebildiği ortaya konmuştur.

C.D Rullan-Silva ve arkadaşları (2013)’nın yaptığı çalışmada ise böceklerin sebep olduğu orman hasarlarını tespit etmek, haritalamak ve izlemek için uzaktan algılamanın durumu üzerine 2007-2012 yılları arasında Avrupa ve Amerika da ki farklı ülkelerde yapılan araştırmaları incelemiştir. Yapılan araştırmalara ve incelemelere göre orman sağlığı izlemesinde MODIS uydusunun erken tespit, fonksiyonel ve fizyolojik modelleme de daha iyi olması nedeniyle Landsat uydu verilerine göre daha uygun olduğu kararına varılmıştır. Landsat uydu verilerinin ise yaprak dökümü tespitinde iyi olduğu ancak kaba zamansal çözünürlüğe sahip olması nedeniyle operasyonel izleme için uygun olmadığı kanısına varılmıştır. Ayrıca böcek hasarı tespitinde, yansıtma özelliklerinden türetilen ve bitki örtüsü

değişikliğini göstermek için üretilen bitki örtüsü indekslerinden, SWIR/NIR tabanlı indekslerinin daha uygun olduğu kabul edilse de bugüne kadar NDVI indeksinin, haşerelerin yaprak dökümünü göstermek ve haritalamak için en çok kullanılan bitki örtüsü indeksi olduğu tespit edilmiştir. Son olarak böcek yaprak dökümü izleme için uygun olan iki yöntem vurgulanmıştır. Bunlardan ilki, alt piksel tanıma ve analiz kapasitesi yeteneğine sahip olması nedeniyle Spectral Mixture Analizi'dir. İkinci yöntem ise iki tarih arasındaki bitki endeksi değişim farkının modelleri kullanılarak hasar derecesinin sınıflandırmasıdır. Bu yöntem yaprak dökülmesini tahmin etmek için uygundur. Yapılan tüm araştırmalar sonucunda orman sağlığına yönelik diğer uzaktan algılama uygulamalarına kıyasla, böceklerin yaprak dökülmesinin uzaktan izlenmesine ilişkin araştırmaların hala nadir olduğu düşünülmektedir.

Benzer şekilde Anwer ve Singh (2019)'in gerçekleştirdiği çalışmanın temel amacı bitki sağlığını etkileyen haşere ve hastalık sorununu ele almak için jeo-uzamsal teknolojilerin rolünü belirlemektir. Uzaktan algılama verilerinin çoğu yansıyan elektromanyetik radyasyon (EMR) ile toplanmaktadır ve toplanan veriler haritalama ve uzamsal analiz için kullanılmaktadır. EMR, insan gözüyle tespit edilemeyen ancak bitki örtüsü çalışmasına büyük katkı sağlayan kızılötesi spektrumdadır. Spektrum, bitki örtüsünün spektral özellikleri, bitki örtüsü türü, bitkilerin sağlık durumu, ormanlar vb. hakkında bilgi vermektedir. Bu amaçla yapılan araştırmalarla jeo-uzamsal teknolojinin böcek zararlıları ve hastalık kontrolleri için ormancılık alanını daha kesin ve kapsamlı hale getirdiği kanısına varılmıştır. Bu teknoloji, böcek zararlılarının verdiği zararın araştırılmasından gelecek tahminlerine kadar kullanılmaktadır. Araştırmalar sonucunda, jeo-uzamsal teknolojinin böcek zararlılarının ve tarım mahsulleri, orman vb. hastalıklarının yönetimi için ve tarımda, ormancılıkta üretkenlik ve karar vericiler içinde çok önemli bir rol oynadığı kararına varılmıştır.

Zararlıların tahmin modelinde uzaktan algılama kullanımına olan ilgiyi artırmak amacıyla nesnelerin spektral imzalarının ve bitki indekslerinin kullanımıyla zararlıların izlenmesi gerçekleştirilen bir diğer çalışma da Sudha vd., (2018) tarafından gerçekleştirilmiştir. Nesnelere fiziksel özelliklerine, sıcaklıklarına bağlı olarak üzerlerine gelen elektromanyetik spektrumların bir kısmını farklı dalga boylarında yansıtmaktadırlar bu yansımalar nesnelerin spektral imzasını oluşturmaktadır. Bitki örtüsü indeksleri, spektral imzaları kullanır. Örneğin sağlıklı bitkiler yakın kızılötesi bölge de daha yüksek yansıma yaparken sağlıklı bitkiler daha düşük yansıma yapmaktadırlar. Genel olarak tarımda ve özellikle zararlıların ve hastalıkların izlenmesinde bitki örtüsü indekslerinin önemi büyüktür.

Uçaktan fotoğraf/video, uydu kaynaklı multispektral tarama ve termal görüntüleme vb. araçlarla bitki sağlığı izlenmesi, zararlıların tespiti, izlenmesi, kontrolü ve analizi yapılabilmektedir. Ayrıca yaprak pigmentlerine dayalı spektral indeksler, yakın kızılötesinde görüntüleme, Multispektral Uzaktan Algılama (MRS) ile zararlıların verdiği hasar tespit edilebilmektedir.

Hart ve ark.,(1978) Hawaii, El Salvador ve Meksika'daki tropikal meyve sineklerinin konukçu bitkilerinin dağılımını incelemek için hava fotoğrafçılığı kullanırken, Zhou ve ark.,(2010), Filipinler'in kuzeyindeki Luzon'da kahverengi bitkisi, Nilaparvata lugens'in konukçusu için pirinç üretim alanlarını belirlemede SPOT ve Landsat 5 yüksek çözünürlüklü görüntüler kullanmıştır. Bu çalışmalar doğrultusunda zararlıların önceden tahmini ve tespitinde uzaktan algılama tekniklerinin kullanımının üreticilere ve bölgeye ciddi katkı sağladığı sonucuna varılmıştır.

Bunların yanı sıra Abd El-Ghany vd., (2020) gerçekleştirdiği derleme makalesinde uzaktan algılama yöntemlerinin ve uygulamalarının, böcek zararlıları ve bitki hastalıklarının tespitinde ki uygulamaları hakkında bir bakış açısı sunmayı hedeflemişlerdir. Yapılan araştırmalarda böcek zararlılarını izlemekte ve tespitinde video-grafi, radyo frekansı tanımlama (RFID), radyo-telemetri, X-ışınları radyografisi, termal görüntüleme, bilgisayarlı tomografi, radar ve uydular, optik ve optoelektronik cihazlar dahil olmak üzere birçok farklı tekniğin kullanıldığı tespit edilmiştir.

Böcek istilasının tespitinde, havadan uzaktan algılama kullanılarak bildirilen birçok çalışmaya değinilmiştir. Bunlardan bazıları Hart vd.,(1973) havadan CIR (renkli-kızılötesi) fotoğraf ve çok spektral videografi kullanarak narenciye bahçelerindeki ağaçlarda böcek istilasını tespit etmek için yaptığı çalışmadır. Böcek zararlılarının tespiti, analizi için birçok teknik kullanılmasının yanı sıra uzaktan algılama yöntemlerinin başta zararlılar ve bitki hastalıkları yönetimi olmak üzere farklı yaklaşımlarla entegresinin de zararlı yönetimini destekleyen en umut verici yöntemler olduğu kanısını ortaya koyan Fitzgerald G., (2000) büyük ölçekli pamuk tarlalarında akar istilasının erken tespiti için kaba uzamsal çözünürlüklere sahip olan multi spektral uzaktan algılama (MRS) kullanmıştır. Benzer şekilde de Prabhakar vd., (2011) pamuk tarlalarında yaprak biti zararlarının tespitinde yer tabanlı hiperspektral uzaktan algılama yöntemlerini kullanmıştır. Bu çalışmaların dünyadaki örnekleri daha da artırılabilir.

Ülkemizde yapılan çalışmaları incelediğimiz zaman bu konuda yapılan çalışmaların dünyaya kıyasla daha az olduğu görülmektedir. Erbek vd., (2005)'nin, SPOT-2 uydu görüntülerini kullanarak pilot bölge olarak belirledikleri Artvin Atilla Milli Parkı orman alanlarında kabuk böceklerinin verdiği zararı alansal olarak belirlemeyi amaçladığı çalışma bunlardan bir tanesidir. Çalışma da 1997 ve 2002 yıllarına ait görüntüler kullanılmıştır. Görüntüleri kullanmadan önce atmosferik, geometrik düzeltme yapılmış ve aynı koordinat sistemi tanımlanmıştır. Bu işlemler için 1:25 000 ölçekli topoğrafik haritalar ve arazi görüntüleri yardımcı veri olarak kullanılmıştır. Projeksiyon dönüşümü için homojen dağılmış 20 yer kontrol noktası belirlenmiş ve dönüşüm işlemi yapıldıktan sonra zararlıların yoğun olduğu alanlarda GPS ölçümleri yapılarak uydu verilerinde bu alanlara denk gelen yerlerin piksel yansıtımları incelenmiştir. Yakın kızılötesi band (NIR) yansıtım değeri 1997 yılında ortalama 144 iken 2002 yılında bu değer azalarak 41 olduğu görülmüştür. Böcekler tarafından zarara uğrayan orman alanlarını alansal olarak belirlemek için kontrollü sınıflandırma yöntemlerinden olan “En Çok Benzerlik” algoritması kullanılarak sınıflandırma yapılmıştır. Sınıflandırma da yeterli kontrol noktaları belirlenerek 12 sınıf seçilmiştir. Sınıflandırma sonucunda 203 hektar alanın zarara uğradığı tespit edilmiştir. Sınıflandırma doğruluğu için görüntüde test sınıfı belirlenerek hata matrisi ve Kappa değeri hesaplanmıştır. Çalışmanın sonucunda sınıflandırma doğruluğu %82.6, Kappa değeri 0.82 olarak hesaplanmıştır.

Orman zararlılarının, potansiyel yayılış alanlarının tahmini üzerine gerçekleştirilmiş bir diğer çalışma ise Sarıkaya vd., (2019)'nin kızıl kuyruklu kayın tırtılının yayılışını etkileyen çevresel faktörlerin belirlenerek ve olası iklim senaryolarına bağlı olarak günümüzdeki ve gelecekteki potansiyel yayılış yerlerinin belirlenmesini amaçladığı çalışmadır. Bu amaçla, 2050 ve 2070 yılları için tür dağılım modellemesi seçilmiştir. Modelleme de kullanılan veriler için C. pudibunda'nın yayılış gösterdiği alanlarda mevcut literatürlere bağlı olarak 118 noktanın koordinatı belirlenmiştir. Google Satellite Hybrid altlık haritaları kullanılarak WGS 84 koordinat sisteminde belirlenen örnek noktalar seçilerek mevcut yayılış haritası üretilmiştir. Gelecekte potansiyel dağılış yerlerini belirlemek için IPCC 2014 raporunda ki 19 adet biyoklimatik değişken (yıllık ortalama sıcaklık, yıllık yağış, mevsimsel yağış miktarı vb.) baz alınmış ve önem derecelerine göre modelleme yapılmıştır. Modellemeler de AUC değeri, aynı veri seti üzerinde eğitilmiş iki modelin başarısının karşılaştırmasında kullanılmaktadır. Modelleme sonuçlarında AUC değerinin 0.936 olması yani 0.5'ten büyük olması nedeniyle modelin rastgele bir tahminden

daha iyi olduğu sonucuna yani modelin yüksek bir tahmin gücüne sahip olduğu sonucuna varılmıştır. Modelleme sonuçlarına göre tahmini yayılış haritaları oluşturulmuştur. Buna göre, zararlının günümüzdeki potansiyel yayılış alanının Karadeniz bölgesi başta olmak üzere kayının mevcut olduğu alanlarda büyük oranda örtüştüğü görülmüştür. Ayrıca 2050-2070 yılları içinde türün yayılış alanları modeli incelendiğinde türün gelecek içinde bir tehdit oluşturduğu gözlenmiştir.

Sarıkaya vd., (2021) tarafından gerçekleştirilen Kütahya-Domaniç, Bursa-İnegöl sınırında yer alan Tahtaköprü mevkiî içerisinde yer alan kayın alanlarında inceleme ve araştırma yapılmıştır. Bu çalışma için dronelara RGB mono kameralar entegre edilmiş ve 30 günlük periyotlarla zararlının etki ettiği alanlar ve ilerleme yönü tespit edilmiştir. Çalışma sonucunda çok bantlı ortofoto harita üretilerek 2019 yılı sonu itibariyle zarara uğrayan alan 453,80 hektar olarak hesaplanmıştır. Ayrıca zararın yoğun olarak 1100-1300 m yükselti basamağında olduğu tespit edilmiştir. Bu çalışmalardan farklı olarak Karaköse vd., (2013)'nin temel amacı 1984-2011 yıllarını kapsayan dönemde Çamlıhemşin Orman Planlama Biriminin habitat çeşitliliğini ortaya koymak ve konumsal değişimleri izlemek üzerine yaptığı çalışmadır. Ancak bu çalışmanın sonucunda da orman zararlılarının etkilerine rastlanılmıştır. Çalışma için 1984 ve 2011 yıllarına ait orman amenajman meşcereleri haritaları altlık olarak kullanılmıştır. Konumsal veri tabanları aracılığıyla EUNIS habitat sınıflandırma sisteminin kriterlerine göre habitat tipleri belirlenerek habitat tipleri haritaları oluşturulmuştur. Habitat tipleri haritalarının yaklaşık 27 yıllık değişimi incelendiğinde çalılıklardan oluşan habitat tipinin ilk yıllarda ki haritalarda mevcut olmadığı ancak son dönemde ki haritalarda mevcut olduğu gözlenmiştir. Bunun nedeni ise ilk dönem hazırlanan amenajman planı meşcere haritasının hazırlanmasında siyah-beyaz hava fotoğrafları kullanılırken, son dönemde hazırlanan meşcere haritasında ise yüksek çözünürlüklü uydu görüntülerinin kullanılmasıdır. Uydu verileri bu habitat tipinin ayırt edilmesini kolaylaştırmıştır. Yapılan konumsal analizlerle 1984-2011 yılları arasında ki süreçte habitat tiplerinin parçalılığının arttığı sonucuna varılmıştır. Habitat tiplerinin parçalılığının artmasının nedenlerinden birisinin de kabuk böceklerinin verdiği zararlar olduğu tespit edilmiştir. Verilere göre planlama birimi 2003 yılından beri kabuk böceği ile biyolojik mücadele çalışmaları yapmaktadır. Yıllık ortalama 420 ha'lık bir alanda biyolojik mücadele yapılmakta olup çalışmalar sonucunda 2011 yılına kadar toplamda 108 adet ağacın zarar gördüğü belirlenmiş ve ayrıca bunun da 311 m<sup>3</sup> odun üretimine karşılık geldiği tespit edilmiştir.

Orman sađlıđının izlenmesine Chen vd., (2021) farklı bir bakış sunarak Google Earth Engine platformunda Landsat zaman serilerinin kullanarak Gürcistan için 1984-2019 yılları orman bozulmalarını izlemiştir. %91 genel dođruluk deđerlendirmesiyle orman bozulmalarını başarılı bir şekilde göstermiştir.

## **2.1. Orman Sađlıđını İzlemede Kullanılan Bitki İndeksleri**

Ormanların izlenmesi ve zamansal deđişikliklerinin analizi orman sađlıđı için önemli konulardan birisidir. Geleneksel yöntemlerle orman sađlıđının izlenmesi hem maliyetli hemde vakit alıcıdır bu nedenle ormancılık faaliyetlerini etkin kullanabilmek ve daha sađlıklı izlemeler yapabilmek amacıyla uydu verilerinin kullanımı artırılmıştır. Bununla birlikte, bitki indekslerinin kullanılması, orman sađlıđı izlenmesini ve zararlıların tespitini kolaylaştırmakta, ekonomik ve hızlı olarak takip edilmesini sađlamaktadır. Orman sađlıđını izlemede kullanılan bir çok bitki indeksi vardır (Aghlmand vd., 2021, Yılmaz vd., 2019, Cruz vd., 2020). Bu indekslerden bazıları NDVI (Normalleştirilmiş Fark Bitki Örtüsü Endeksi), EVI (Gelişmiş Bitki Örtüsü Endeksi), SAVI (Toprak Ayarlı Bitki İndeksi), RVI (Oran Bitki İndeksi), TVI (Dönüştürülmüş Bitki İndeksi), NPCRI (Normalize Pigment Klorofil Oranı İndeksi) indeksleridir.

### **2.1.1. Normalleştirilmiş Fark Bitki Örtüsü Endeksi (NDVI)**

Yeşil bitki örtüsünün izlenmesinde en çok kullanılan indeks NDVI'dır (Yıldız vd., 2012). Yakın kızıl ötesi (NIR) ve kırmızı (RED) ışık dalga boyunda algılama yapan bantlardan hesaplanan NDVI, bitkilerin biyokütle miktarı ve yaprak alan indeks deđerinin ana göstergesidir. Bu nedenle bitki gelişiminin izlenmesi amacıyla kullanılmaktadır (Yıldız vd., 2012). NDVI'ya ait formül (Eşitlik 2.1.1) 'de verilmiştir.

$$NDVI = (NIR - RED) / (NIR + RED) \quad (2.1.1)$$

NDVI değerleri (-1) ile (+1) arasında değer almaktadır. İndeks değeri +1'e doğru yaklaşırken yeşil bitki örtüsünün fazla olduğu, bitkinin canlılığının yüksek olduğunu -1'e yaklaşırken ise bulut, su, kar, bitki örtüsünün yoksunluğu, ölü bitki örtüsü olduğunu ifade etmektedir.

### 2.1.2. Gelişmiş Bitki Örtüsü İndeksi (EVI)

Gelişmiş bitki örtüsü indeksi olan EVI bir toprak ayarlama faktörü olup NDVI modifikasyonudur. Bitki örtüsü sinyalini, bitki örtüsünden arka plan sinyalinin ayrılması ve atmosferik etkilerin azaltılması ayrıca yüksek biyokütle bölgelerinde gelişmiş hassasiyet ile bitki örtüsünün izlenmesi için geliştirilmiş bir "optimize" indekstir (Soydan vd., 2020). L gölgelik arka plan parametresi, C1 ve C2 aerosol direnç katsayılarından oluşan indeks sırasıyla 1, 6, 7.5 ampirik olarak belirlenen katsayı değerlerini almaktadır (Soydan vd., 2020). Bu bitki indeksine ait formül ve değerler Eşitlik 2.1.2'de verilmiştir.

$$EVI = G*(NIR - RED) / (NIR + C1*RED - C2 * BLUE +L) \quad (2.1.2)$$

$$G= (GAIN FACTOR) =2.5 \quad C1=6 \quad C2 = 7.5 \quad L=1$$

### 2.1.3. Toprak Ayarlı Bitki İndeksi (SAVI)

Bitki örtüsü gölgelenmelerinden kaynaklanan kırmızı ve yakın kızılötesi yansımaların yok edilmesini açıklamaktadır. Yani toprak parlaklığını en aza indirerek bitki örtüsünden gelen verileri göstermektedir. Formülünde bulunan L parametresi arka plan ayar faktörü olup aldığı değer bitki örtüsü yoğunluğuna göre değişmektedir (Kaya vd., 2021). 0 ile 1 arasında değer alan L parametresi bitki örtüsünün yoğun olduğu yerlerde 0 ya da 0'a çok yakın değer alırken bitki örtüsünün seyrek olduğu yerlerde 1 veya 1'e yakın değer almaktadır (Eşitlik 2.3.3).

$$SAVI= ((NIR-RED)/(NIR+RED+L))* (1 + L) \quad (2.1.3)$$

#### 2.1.4. Oran Bitki İndeksi (RVI)

Kırmızı bantın yakın kızılötesi banta oranlanmasıyla elde edilen indekstir. Atmosferik koşullar gibi faktörlerden dolayı görüntülerdeki gürültüden etkilenmektedir. Bitki örtüsündeki büyümeyi gösteren bu indeksinde 20 gibi yüksek değerler yoğun bitki örtüsünü, 1 gibi düşük değerler toprak, buz ve suyun varlığını göstermektedir (Akkartal vd., 2005).

$$RVI = RED / NIR \quad (2.1.4)$$

#### 2.1.5. Dönüştürülmüş Bitki İndeksi (TVI)

NDVI'ın karekökü alınarak negatif değerleri kaldırmayı ve NDVI histogramlarını dönüştürmeye çalışan bitki örtüsü indeksidir. Sonucun her zaman NDVI ile aynı olması gerekmektedir bu nedenle de bazı farklılıklar ortaya çıkmaktadır (Taşçı, 2018).

$$TVI = \sqrt{NDVI + L} \quad (2.1.5)$$

#### 2.1.6. Normalize Pigment Klorofil Oranı İndeksi (NPCRI)

NPCRI, klorofil içeriği ile ilişkili bir indeks olup tarım ve ormancılıkta kullanılmaktadır. Kırmızı ve mavi spektral bantları kullanan NPCRI, klorofil ve azotu ölçmek için gereken bilgileri yakalamaktadır (Peñuelas vd., 1994).

$$NPCRI = (RED - BLUE) / (RED + BLUE) \quad (2.1.6)$$

## 2.2. Uydu Görüntüleri

Uydu görüntüleri, kısaca görüntüleme uyduları tarafından toplanan Dünya'ya ait görüntülerdir. Apple Haritalar ve Google Haritalar gibi uydu görüntüleme şirketleri işletmelere ve hükümetlere lisans vererek görüntüleri satmaktadır (URL-9, 2022). Uyduların çalışma prensibi dijital kameraların çalışma prensibiyle aynıdır. Uydular üzerindeki algılayıcılar elektromanyetik enerjinin miktarını ölçen binlerce küçük alıcılardan oluşmaktadır. Yeryüzünden ve yeryüzünde bulunan objelerden yansıyan enerjileri toplamaktadır ve bu işleme spektral ölçüm adı verilmektedir. Her spektral yansıma değerinin bir dijital sayı karşılığı vardır. Bu sayılar, bilgisayarlar tarafından renklere ve gri-renk tonlamasındaki parlaklık seviyelerine göre görüntülere dönüştürülmektedir.

Landsat, Sentinel, MODIS, Hyperion, Göktürk-2, Kompsat-3A, Sentinel-2, Kompsat-5, ALOS-2 gibi birçok uydu vardır. Çalışma kapsamında Landsat ve Sentinel uyduları kullanılmıştır.

### 2.2.1. Landsat-8

Landsat 8, NASA'nın Landsat serisindeki sekizinci uydusu olup, yiyecek, su ve ormanlar gibi insani geçim kaynakları için gerekli kaynakların düzenlenmesi, izlenmesindeki en önemli uydudur. İnsanoğlu nüfusu dünya üzerindeki etkisi arttıkça ve yaşamaya devam ettikçe, Landsat çevresel değişimleri izlemeye devam edecektir.

Landsat 8, Landsat 7'nin yörüngesine katılmış olup bilimsel verilerde sunmaktadır. Landsat 8 uydusu, görünür, yakın-infrared, kısa dalga infrared ve termal infrared aralıklarında görüntü almakta olup, spektral aralığa bağlı olarak 15 ile 100 metre arasında bir orta uzamsal çözünürlüğe sahiptir. Landsat 8 NASA ve USGS (U.S. Geological Survey) arasındaki işbirliği ile üretilmiştir (URL-10, 2022).

Çalışma da "Landsat 8 Collection 1 Tier 1 TOA Reflectance" verisi kullanılmış olup atmosferik düzeltmeleri GEE tarafından kalibre edilmiş şekilde sunulmaktadır.

Tablo 1. Landsat 8 Collection 1 Tier 1 TOA Reflectance bant bilgisi (Oğuz, 2017)

Spektral Aralık	Dalgaboyu	Çözünürlük
Band 1 - Kıyı/ Aerosol	0.433 - 0.453 $\mu\text{m}$	30 m
Band 2 - Mavi	0.450 - 0.515 $\mu\text{m}$	30 m
Band 3 - Yeşil	0.525 - 0.600 $\mu\text{m}$	30 m
Band 4 - Kırmızı	0.630 - 0.680 $\mu\text{m}$	30 m
Band 5 -Yakın Infrared	0.845 - 0.885 $\mu\text{m}$	30 m
Band 6 - Kısa Dalga Infrared	1.560 - 1.660 $\mu\text{m}$	30 m
Band 7 - Kısa Dalga Infrared	2.100 - 2.300 $\mu\text{m}$	30 m
Band 8 - Pankromatik	0.500 - 0.680 $\mu\text{m}$	15 m
Band 9 - Sirkus	1.360 - 1.390 $\mu\text{m}$	15 m
Band 10- Termal Infrared 1	10.60 - 11.19 $\mu\text{m}$	30 m
Band 11- Termal Infrared 2	11.50 - 12.51 $\mu\text{m}$	30 m

### 2.2.2. Sentinel-2A

Sentinel-2, Copernic Programı dahilinde olan bir Dünya gözlem uyduları birliğidir. Sentinel-2A ve Sentinel-2B isimli ikiz uydulardan oluşmaktadır. Uyduların, tarımsal izleme, acil durum yönetimi, arazi örtüsü sınıflandırması, su kalitesi, orman ve bitki örtüsü izleme gibi çok çeşitli kullanım alanları ve uygulamaları vardır. Sentinel-2 Avrupa Uzay Ajansı (ESA) tarafından geliştirilmiştir. Yerel, bölgesel, ulusal ve uluslararası ölçeklerde coğrafi veriler sağlamaktadır. Sentinel-2, 13 spektral banda sahip optik bir sensör taşımaktadır ve bu sensör 10 m uzamsal çözünürlükte dört bant, 20 m çözünürlükte altı bant ve 60 m uzamsal çözünürlükte üç banttan oluşmaktadır.

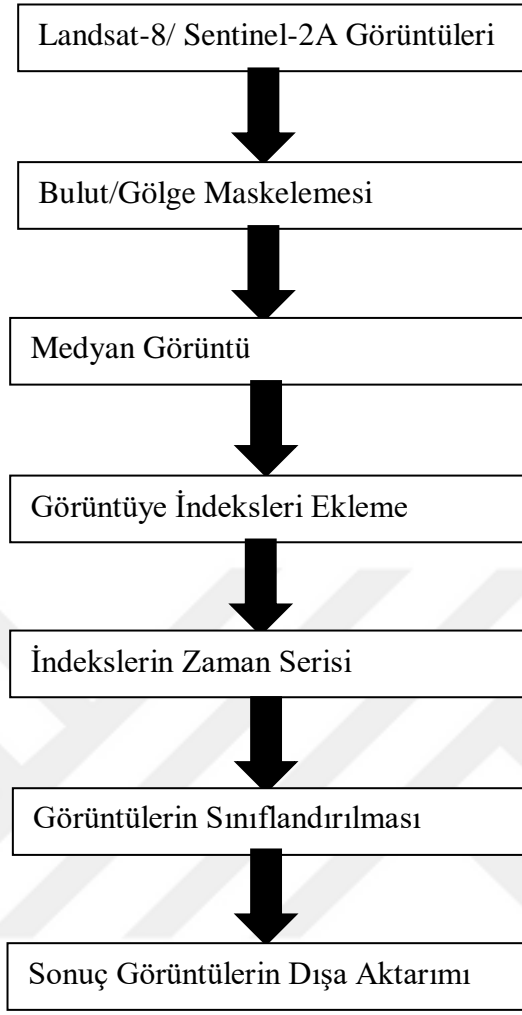
Tablo 2. Sentinel-2 bant bilgisi (Zhang ve ark., 2017)

<b>Spektral Aralık</b>	<b>Dalgaboyu</b>	<b>Çözünürlük</b>
Band 1- Kıyılar ve Aerosol (Coastal/Aerosol)	0.433 – 0.453 $\mu\text{m}$	60
Band 2- Mavi (B)	0.458 – 0.523 $\mu\text{m}$	10
Band 3- Yeşil (G)	0.543 – 0.578 $\mu\text{m}$	10
Band 4- Kırmızı (R)	0.650 – 0.680 $\mu\text{m}$	10
Band 5- Vejetasyon Red Edge	0.698 – 0.713 $\mu\text{m}$	20
Band 6- Vejetasyon Red Edge	0.733 – 0.748 $\mu\text{m}$	20
Band 7- Vejetasyon Red Edge	0.773 – 0.793 $\mu\text{m}$	20
Band 8- NIR (Yakın Kıızıl Ötesi)	0.785 – 0.900 $\mu\text{m}$	10
Band 8A- Narrow NIR (Daraltılmış Yakın Kıızıl Ötesi)	0.855 – 0.875 $\mu\text{m}$	20
Band 9- Su buharı (Water vapour)	0.935 – 0.955 $\mu\text{m}$	60
Band 10- SWIR – Cirrus (Kısa Dalga Kıızıl Ötesi)	1.365 – 1.385 $\mu\text{m}$	60
Band 11- SWIR-1 (Kısa Dalga Kıızıl Ötesi-1)	1.565 – 1.655 $\mu\text{m}$	20
Band 12- SWIR-2 (Kısa Dalga Kıızıl Ötesi-2)	2.100 – 2.280 $\mu\text{m}$	20

### 3. YAPILAN ÇALIŞMALAR

Google Earth Engine platformu üzerinden uzaktan algılama sınıflandırma yöntemleri ve uydu verileri kullanılarak orman sağlığının izlenmesi, tespiti ve analizi ile ilgili yapılan bütün çalışmalara bu bölümde yer verilecektir.

Çalışmada önce literatür taraması yapılmış, kullanılacak uydu verilerine, yazılımlara ve yöntemlere karar verilmiştir. Daha sonra orman zararlılarından etkilenmiş bir alan çalışma alanı olarak belirlenmiş ve çalışma alanına ait uydu görüntüleri elde edilmiştir. Orman sağlığını izlemek için 4 yıllık bir tarih aralığı seçilmiş ve bu tarih aralığında Sentinel-2A ve Landsat-8 uydularıyla elde edilmiş görüntüler düzenlenmiştir. Düzenlenen görüntülerin medyanı alınarak işlemler bu görüntünün üzerinde gerçekleştirilmiştir. Bu bölümde, görüntüler üzerinde bulut ve gölge maskeleymesi, bitki indeksleri ile analizler, zaman serileri analizi ve sınıflandırma işlemleri uygulanmıştır. Bu işlemlerin sonucunda elde edilen çıktı veriler analiz edilerek yorumlanmış ve görselleştirilmiştir. Son olarak indeks yöntemleri, sınıflandırma yöntemleri ve uydu verileri kıyaslanarak orman sağlığı izlenmesine olan katkıları daha iyi olduğunu karar verilerek çalışma sonlandırılmıştır. Bütün yapılan çalışmaları içeren iş akış şeması Şekil 22'de, verilmiştir.

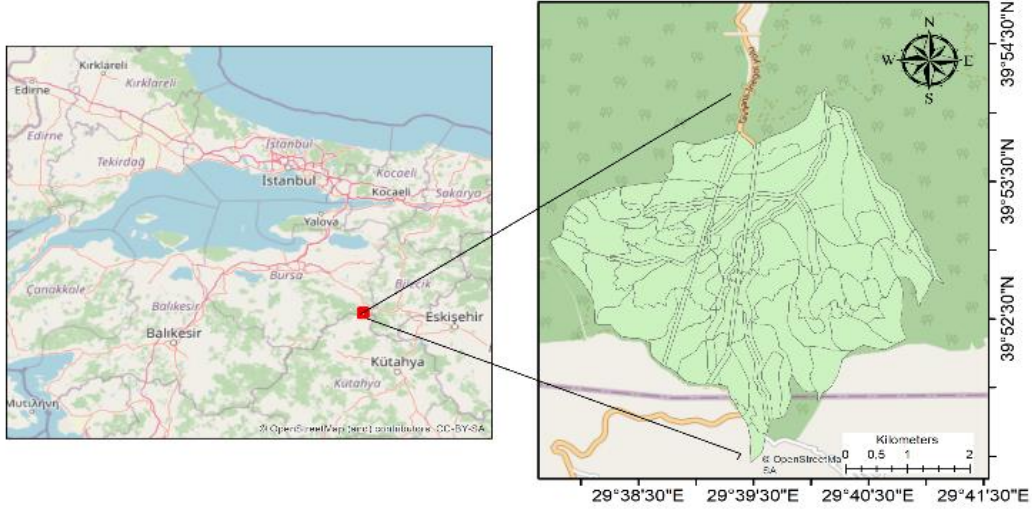


Şekil 22. Çalışma iş akış şeması

### 3.1. Çalışma Alanı

Çalışma alanı olarak Bursa-İnegöl ve Kütahya-Domaniç sınırında bulunan yaklaşık 1225 ha'lık bir alana sahip olan Tahtaköprü mevki seçilmiştir (Şekil 23.). Tahtaköprü mahallesi, 39°56'46.82" enlem, 29°38'38.84" boylam coğrafi koordinatlarına sahiptir. Bölgenin başta kayın ağaçları olmak üzere çeşitli orman türlerine sahip olması çalışma alanı olarak belirlenmesinin nedenlerindedir. Ayrıca kayın ağaçlarına zarar veren orman zararlısı kızılkuşuklu kayın tırtılı (*Calliteara pudibunda*)'nın bu bölgede önemli ölçüde zarara neden olduğu yapılan araştırmalar ve literatür taramaları sonucunda tespit edilmiştir (Sarıkaya vd., 2019; Sarıkaya vd., 2021).

## Çalışma Alanı-Tahtaköprü



Şekil 23. Çalışma alanı

### 3.2. Çalışmada Kullanılan Veriler ve Yazılımlar

Sınıflandırma yapabilmek için ilk olarak belirlenen tarih aralıklarına ait uydu görüntülerinin temin edilmesi gerekmektedir. Uydu verileri, uydu görüntüleme şirketleri tarafından işletmelere, hükümetlere, bilimsel veya ticari amaçlı kullanılmak üzere sunulmaktadır. Tez kapsamında kullanılan Sentinel-2A ve Landsat-8 uydu sistemlerine ait veriler GEE üzerinden direkt olarak seçilip ilgili tarih aralığında daraltılmış ve medyan görüntüler kullanılmıştır. Çalışmada kullanılan verilere ait bilgiler Tablo 3 ve 4'te verilmiştir. GEE bünyesinde barındırılan uydu verileri atmosferik düzeltmesi yapılmış uydu verileri olduğundan sadece bulut ve gölge maskeleymesi uygulanmıştır. GEE, açık kaynaklı hazır kod ve kullanıcılara kod yazma imkanı veren bir panel sunmaktadır. Bu nedenle bitki indekslerine ait formüller, maskeleyme ve sınıflandırmaya ait kodlamalar GEE kütüphanesinden ve yapılmış çalışmalara referans alınarak kullanılmıştır. Çalışma sonucu elde edilen çıktı görüntüler ArcGIS 10.7 programı kullanılarak haritalara dönüştürülmüş ve görselleştirilmiştir.

Tablo 3. Landsat kullanılan görüntü ve özellikleri



Görüntü Tarihi	Uydu Serisi	Kullanılan Bantlar	Mekansal Çözünürlük
28.10.2019	Landsat 8 Collection 1 Tier 1 TOA Reflectance	B1, B2, B3, B4, B5, B6, B7, B10, B11	30 m

Tablo 4. Sentinel kullanılan görüntü ve özellikleri

Görüntü Tarihi	Uydu Serisi	Kullanılan Bantlar	Mekansal Çözünürlük
12.10.2019	Sentinel-2A	B2, B3, B4, B8	10 m

### 3.3. Görüntü Seçimi ve Ön İşleme Adımları


Görüntüler seçilirken güncel ve çözünürlüğü yüksek, ormancılık uygulamalarında kullanılan uydu verilerinin seçilmesine dikkat edilerek seçilmiştir. GEE bünyesinde sayısız uydu ve bunlara ait uydu görüntüleri bulunmasına rağmen çalışmada 3 ayrı ön işleme formatında bulunan “USGS Landsat 8 Collection 1 Tier 1 TOA Reflectance” adlı atmosfer üstü yansıtım uydu verileri ve Sentinel Level-1C ve Level-2A formatlarından Level-2A uydu verileri seçilmiştir. Orman sağlığının izlenmesinde 2017-2021 yılları tarih aralığı olarak belirlenmiştir. Bu tarih aralığında Landsat-8 için 163, Sentinel-2A için 200 adet görüntü elde edilmiştir. Bu görüntülerin, .median() komutu ile görüntüdeki tüm piksellerin medyanı alınarak görüntü koleksiyonu azaltılmış ve çalışmaya devam edilmiştir. Çalışma esnasında zararlının epidemiyolojisinin ekim ayında olduğu bilindiğinden ekim aylarındaki değişiklikler öncelikli olarak izlenmiş ve çalışma alanı için 2019 ekim ayına ait veriler dikkat çekmiştir. Bu nedenle izlemeler bu tarih üzerinden gerçekleştirilmiştir. Bu aya ait görüntülere bulut ve gölge maskesi uygulanmış ve bu uygulamadan sonra Sentinel-2A ve Landsat-8 için 4 olan uydu görüntüsü sayısı 1’e düşmüştür. Buna rağmen Landsat-8 uydu görüntüsü için tüm bulutlar giderilememiştir. Yine bu tarihlere ait Landsat-8 uydu görüntüsü Şekil 24’te Sentinel-2A uydu görüntüsü de Şekil 25’te verilmiştir.



### 3.4. Bitki İndeksleri ile Orman Sağlığı Görüntülerinin Oluşturulması


Çalışmada kullanılan bitki indeksleri GEE platformunda filtrelenen görüntüler üzerinden “.expression” kodu kullanılarak indekslerin denklemi yazılmış ve görüntüler oluşturulup Google Drive’a dışa aktarılarak kullanılmıştır. Kullanılan bitki indeksleri NDVI, EVI, SAVI, RVI, TVI, NPCRI indeksleridir. Tüm indeksler için hem Landsat-8 hem Sentinel-2A uydu verilerine ait sonuç görseller eklenmiştir.

#### 3.4.1. NDVI Görüntülerinin Oluşturulması




Şekil 26. Orman zararlılarından etkilenmiş alanın NDVI görüntüsü (a) Landsat-8’e ait NDVI görüntüsü (b) Sentinel-2A’ya ait NDVI görüntüsü

### 3.4.2. EVI Görüntülerinin Oluşturulması




Şekil 27. Orman zararlılarından etkilenmiş alanın EVI görüntüsü (a) Landsat-8'e ait EVI görüntüsü (b) Sentinel-2A'ya ait EVI görüntüsü

### 3.4.3. SAVI Görüntülerinin Oluşturulması




Şekil 28. Orman zararlılarından etkilenmiş alanın SAVI görüntüsü (a) Landsat-8'e ait SAVI görüntüsü (b) Sentinel-2A'ya ait SAVI görüntüsü

### 3.4.4. RVI Görüntülerinin Oluşturulması




Şekil 29. Orman zararlılarından etkilenmiş alanın RVI görüntüsü (a) Landsat-8'e ait RVI görüntüsü (b) Sentinel-2A'ya ait RVI görüntüsü

### 3.4.5. TVI Görüntülerinin Oluşturulması



Şekil 30. Orman zararlılarından etkilenmiş alanın TVI görüntüsü (a) Landsat-8'e ait TVI görüntüsü (b) Sentinel-2A'ya ait TVI görüntüsü

### 3.4.6. NPCRI Görüntülerinin Oluşturulması



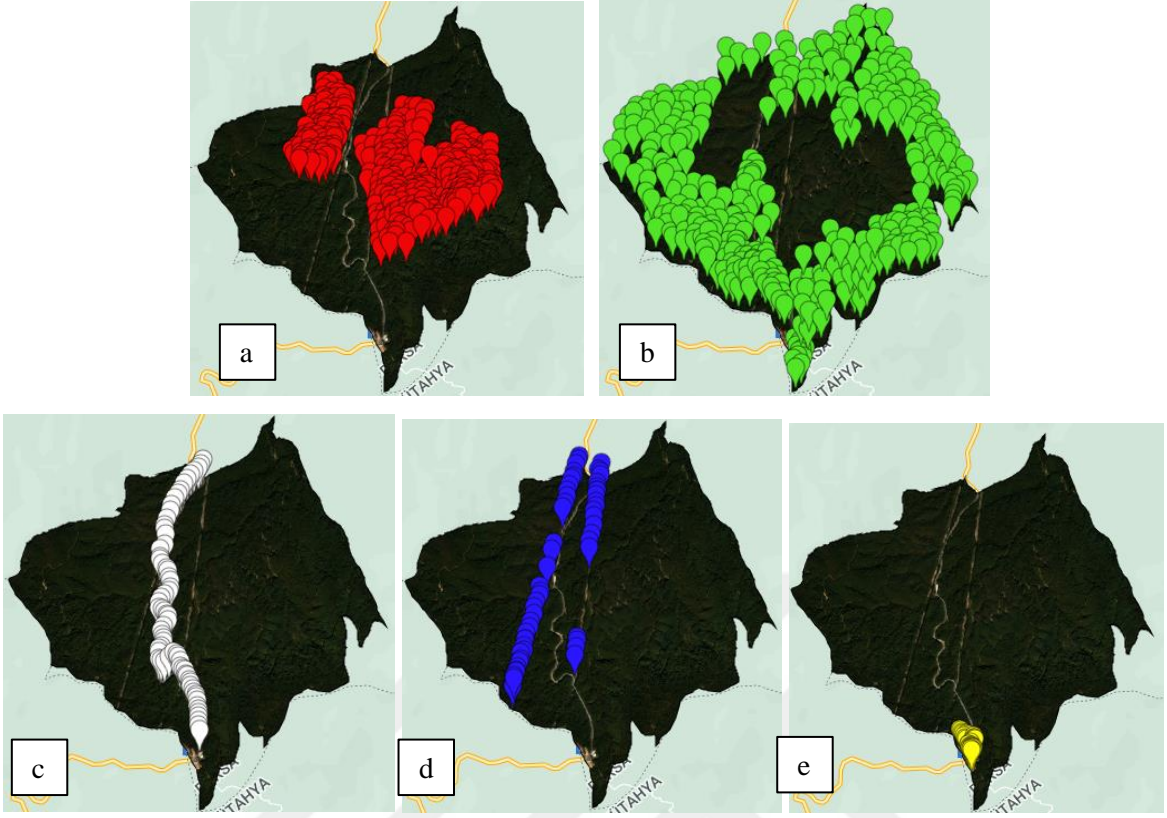
Şekil 31. Orman zararlılarından etkilenmiş alanın NPCRI görüntüsü (a) Landsat-8'e ait NPCRI görüntüsü (b) Sentinel-2A'ya ait NPCRI görüntüsü

### 3.5. Görüntülerin Sınıflandırılması

Görüntüleri sınıflandırmak için orman zararlılarından etkilenmiş alanlar hastalıklı, etkilenmemiş alanlar sağlıklı, yol, elektrik hattı ve yerleşim olmak üzere 5 adet sınıf seçilmiştir. Her sınıf için Landsat 8'e göre daha yüksek çözünürlüklü uydu verilerine sahip olan Sentinel-2A üzerinden sırasıyla 338, 366, 72, 57, 27 eğitim verisi seçilmiştir. Seçilen verilerin %70'i eğitim verisi için ve %30'u ise test grubu için sınıflandırmada kullanılmıştır (Tablo 5.).

Tablo 5. Sınıflandırma bilgileri ve nokta sayıları

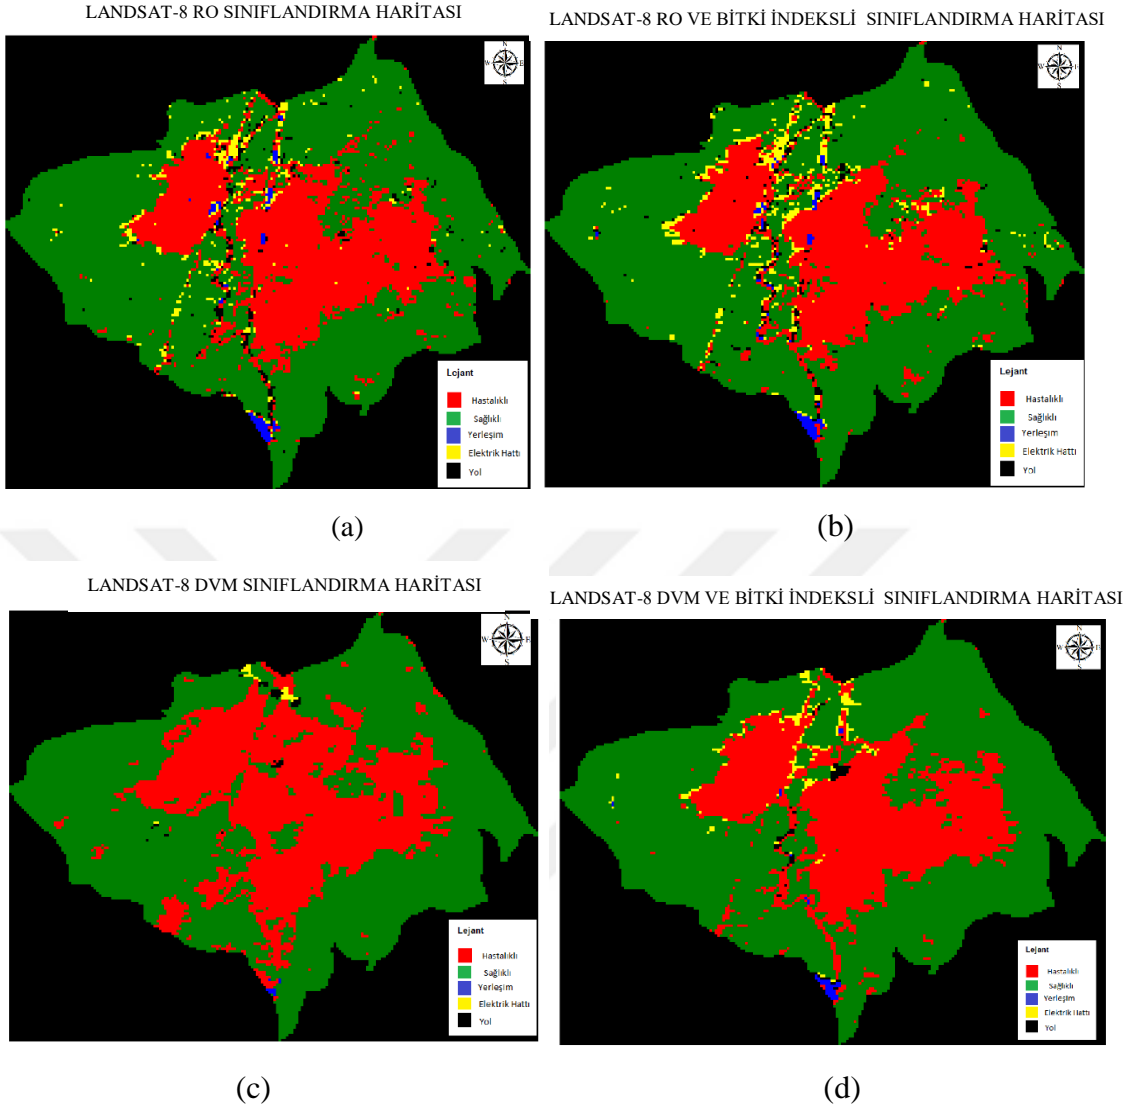
No.	Adı	Sınıf	Eğitim Noktaları	Test Noktaları
1	Hastalıklı Alan		237	101
2	Sağlıklı Alan		256	110
3	Yollar		50	22
4	Elektrik Hattı		40	17
5	Yerleşim		19	8



Şekil 32. Eğitim verisi (a: hastalıklı b: sağlıklı c: yol d: elektrik hattı e: yerleşim)


Sınıflandırma işlemi 2 farklı veri setiyle gerçekleştirilmiştir. İlk olarak bitki indeksleri kullanılmadan Landsat-8 ‘in sahip olduğu 30 m çözünürlüklü Band 1, 2, 3, 4, 5, 6, 7, 10 ve 11 bantları ve Sentinel-2A uydusunun 10 m çözünürlüklü Band-2,3,4 ve 8 bantları kullanılarak sınıflandırma yapılmıştır. Daha sonra bitki indeksleri bir bant olarak kabul edilip görüntüye ve sınıflandırmaya dahil edilerek sınıflandırma yapılmıştır. Makine öğrenmesi algoritmalarından RO için sınıflandırmada kullanılan ağaç sayısı 10, DVM’ler için GEE’ye ait “ee.Classifier.libsvm” sınıflandırıcısı kullanılmış olup kernelType parametresi için “RBF”, gamma parametresi için “0.5” ve cost parametresi için “10” değerleri seçilmiştir. Ayrıca görüntüler nesne tabanlı olarak da sınıflandırılmış olup piksel segmentasyon boyutu 15 seçilmiştir. Seçilen parametreler, eğitim veri setlerinin en iyi performansına göre belirlenmiştir.

Sınıflandırma sonucu oluşan görüntüler görselleştirilerek haritalara dönüştürülmüştür. Landsat-8’e ait sınıflandırma haritaları Şekil 33’te, Sentinel-2A’ya ait sınıflandırma görüntüleri Şekil 34’te verilmiştir. Nesne tabanlı sınıflandırmaya ait sınıflandırma sonuçları da Şekil 35’te verilmiştir.




Şekil 33. Landsat-8 (L8) uydu verisi için RO ve DVM yöntemi ile piksel tabanlı sınıflandırma (a) Landsat-8 bitki indeksiz RO sınıflandırma haritası (b) Landsat-8 bitki indeksli RO sınıflandırma haritası (c) Landsat-8 bitki indeksiz DVM sınıflandırma haritası (d) Landsat-8 bitki indeksli DVM sınıflandırma haritası

SENTİNEL-2 DVM SINIFLANDIRMA HARİTASI




(a)

SENTİNEL-2 DVM VE BİTKİ İNDEKSİLİ SINIFLANDIRMA HARİTASI



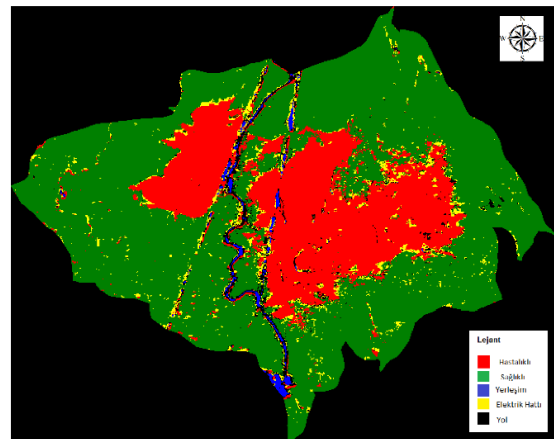
(b)

SENTİNEL-2 RO SINIFLANDIRMA HARİTASI



(c)

SENTİNEL-2 RO VE BİTKİ İNDEKSİLİ SINIFLANDIRMA HARİTASI



(d)

Şekil 34. Sentinel-2A (S2) uydu verisi için DVM ve RO yöntemi ile piksel tabanlı sınıflandırma (a) Sentinel-2A bitki indeksiz DVM sınıflandırma haritası (b) Sentinel-2A bitki indeksli DVM sınıflandırma haritası (c) Sentinel-2A bitki indeksiz RO sınıflandırma haritası (d) Sentinel-2A bitki indeksli RO sınıflandırma haritası



### 3.8. Sınıflandırma Sonuçları Alan Grafikleri

“ui.Chart.image.byClass” komutu kullanılarak her bir sınıfa ait piksellerin toplanmasıyla sınıfların gerçek arazi yüzeyinde kapladığı alan miktarı hesaplanmış ve grafiksel olarak GEE’nin konsol alanına yazdırılmıştır. Şekil 36’da her bir sınıf için hesaplanan alan grafiğinin örneği gösterilmiştir. Daha sonra yıllık olarak her bir sınıf için hesaplanan alan değeri Excell platformuna aktarılmış ve grafiksel olarak gösterilmiştir.




Şekil 36. Sınıflandırma sonucu alan grafiği

#### 4. BULGULAR VE İRDELEME

Bu bölümde, Tahtaköprü mevki kayın ağaçlarından oluşan ve kızılkuyruklu kayın tırtılı (*Calliteara Pudibunda*) tarafından zarara uğramış ormanlık alanın yapılan çalışmalar kapsamında orman sağlığı izlenmesi, tespiti, analizi ve yorumlanmasına dair gerçekleştirilen çalışmaların sonuçları gösterilip irdelenecek ve sonuçlar karşılaştırılacaktır.

##### 4.1. Tahtaköprü Mevkii Orman Sağlığının İzlenmesi

Kütahya-Domaniç, Bursa-İnegöl sınırında bulunan kayın ağaçlarınınca zengin olan Tahtaköprü mevki 2019 yılı ekim ayında kızılkuyruklu kayın tırtılı (*Calliteara Pudibunda*) tarafından ciddi zarara uğramıştır. Epidemiye neden olan bu orman zararlısının epidemi öncesi (2018-ekim), epidemi zamanı (2019-ekim) ve epidemi sonrasına (2020-ekim) ait Sentinel-2A uydusuna ait uydu görüntüleri Şekil 37’de verilmiştir.



Şekil 37. Kızılkuyruklu kayın tırtılı (*Calliteara Pudibunda*) etkisi (a: Epidemi öncesi 07.10.2018, b: Epidemi zamanı 12.10.2019, c: Epidemi sonrası 11.10.2020)

Salgının 2018 ekim ayında başladığı, 2019 ekim ayında artarak ilerlediği ve 2020 yılında tamamen bittiği görülmektedir. Çalışma alanına ait saha görüntüsü de Şekil 38’de verilmiştir.



Şekil 38. Çalışma alanına ait hava araçlarıyla elde edilmiş saha görüntüsü

#### 4.2. Sınıflandırma Sonuçlarının Karşılaştırılması

Uydu verileriyle ve bitki indeksleriyle de orman sağlığı izlemesi yapılmış ve zararlılardan etkilenen alan görselleştirilmiştir. Daha sonra DVM ve RO sınıflandırma algoritmalarıyla piksel tabanlı ve nesne tabanlı sınıflandırmalar yapılmış ve bu sınıflandırmalarda uydu görüntülerinin sahip olduğu bantların yanı sıra indeksler de bir bant gibi sınıflandırmaya dahil edilmiştir. Sınıflandırmalar, bitki indekslerinin dahil olduğu ve olmadığı şekilde 2 türlü yapılmış ve her bir sınıflandırma için genel doğruluk ve kappa katsayısı hesaplanmıştır. Sınıflandırma sonuçlarına ait veriler Tablo 6 ve 7' de verilmiştir.

Tablo 6. RO ile tüm kombinasyonlar için genel doğruluk ve kappa katsayısı sonuçları

RASTGELE ORMAN SINIFLANDIRMA ALGORİTMASI(RO)		
Kombinasyon	Genel Doğruluk(%)	Kappa Katsayısı(%)
Sentinel-2A (S2)	90.34	85.10
Landsat-8 (L8)	85.70	77.39
S2+NDVI+SAVI+TVI+RVI+NPCRI+EVI	90.81	85.79
L8+NDVI+SAVI+TVI+RVI+NPCRI+EVI	85.58	77.33

RO sınıflandırması için Tablo-4 incelendiği zaman bitki indekslerinin sınıflandırmaya dahil edildiğinde Sentinel-2A uydu verisiyle yapılan sınıflandırma için %90.34 ‘ten %90.81’e yükselterek daha iyi bir sonuç verdiğini ancak Landsat-8 uydu verileriyle yapılan sınıflandırma için bitki indekslerinin sınıflandırmaya dahil edilmesi sonucunda genel doğruluk değerinin %85.70’ten %85.58’e düştüğü görülmüştür. Ayrıca RO sınıflandırmasının Sentinel-2A sınıflandırması için %90.34, Landsat-8 sınıflandırması için %85.70 genel doğruluk değerini vermesi RO’nun Sentinel-2A verileri için daha iyi bir yöntem olduğunun göstergesidir.

Tablo 7. DVM ile tüm kombinasyonlar için genel doğruluk ve kappa katsayısı sonuçları

DESTEK VEKTÖR MAKİNELERİ (DVM)		
Kombinasyon	Genel Doğruluk(%)	Kappa Katsayısı(%)
S2	97.78	96.60
L8	75.90	59.76
S2+NDVI+SAVI+TVI+RVI+NPCRI+EVI	98.48	97.68
L8+NDVI+SAVI+TVI+RVI+NPCRI+EVI	84.88	75.37

Tablo-7 incelendiği zaman bitki indekslerinin sınıflandırmaya dahil edilmesiyle Sentinel-2A sınıflandırması genel doğruluk değeri %97.78'den %98.48'e çıkarken Landsat-8 sınıflandırması %75.90'dan %84.88'e çıktığı yani DVM yöntemiyle sınıflandırmanın Landsat-8 verileri için daha iyi bir tercih olduğu görülmüştür.

Sınıflandırma sonuçlarından sonra her bir sınıfa ait kullanıcı ve üretici doğruluk değerleri hesaplanarak bu değerlere ilişkin sonuçlar Tablo 8-9-10-11'de gösterilmiştir.

Tablo 8. Landsat-8 RO ve Landsat-8 Bitki İndeksli RO sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri

Landsat-8 RO				Landsat-8 Bitki İndeksli RO			
Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)	Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)
Hastalıklı	86.22	94.38	90.11	Hastalıklı	86.48	94.67	90.39
Sağlıklı	90.93	95.90	93.35	Sağlıklı	92.06	95.08	93.55
Yerleşim	67.44	40.27	50.43	Yerleşim	62.16	31.94	42.20
Elektrik Hattı	60.87	24.56	35	Elektrik Hattı	62.5	35.08	44.94
Yol	63.16	88.88	73.85	Yol	58.14	92.59	71.43

Landsat-8 uydu verisiyle yapılan RO sınıflandırması sonucu yapılan doğruluk analizi incelendiğinde sağlıklı alanların hem üretici hem kullanıcı hem de F-score doğruluğunda en yüksek sınıfa sahip olduğu görülmektedir. Bitki indeksleri dahil edildiğinde de yine en yüksek sınıflandırma doğruluğunun sağlıklı sınıfa ait olduğu görülmüştür.

Tablo 9. Landsat-8 SVM ve Landsat-8 Bitki İndeksli SVM sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri

Landsat-8 SVM				Landsat-8 Bitki İndeksli SVM			
Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)	Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)
Hastalıklı	68.63	89.35	77.64	Hastalıklı	79.27	97.34	87.38
Sağlıklı	81.23	89.89	85.34	Sağlıklı	91.54	97.54	94.45
Yerleşim	100	34.6	26.67	Yerleşim	88.46	85.18	30.77
Elektrik Hattı	100	35.78	67.79	Elektrik Hattı	70	12.28	20.90
Yol	33.33	14.25	51.43	Yol	73.68	19.44	86.79

Landsat-8 uydu verileri kullanılarak SVM yöntemiyle yapılan sınıflandırma sonuçları incelendiğinde yerleşim ve elektrik hattı sınıfının kullanıcı doğruluğunda %100 doğruluk verdiği, bitki indeksleri dahil edildiği zaman en yüksek doğruluğu sağlıklı sınıfının verdiği görülmüştür.

Tablo 10. Sentinel-2A DVM ve Sentinel-2A Bitki İndeksli DVM sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri

Sentinel-2A DVM				Sentinel-2A Bitki İndeksli DVM			
Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)	Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)
Hastalıklı	99.11	99.41	91.12	Hastalıklı	100	100	100
Sağlıklı	98.91	99.18	93.98	Sağlıklı	98.90	98.63	98.77
Yerleşim	90.91	97.22	98.63	Yerleşim	97.10	93.05	95.03
Elektrik Hattı	89.80	77.19	83.92	Elektrik Hattı	83.60	89.47	86.44
Yol	96.30	100	100	Yol	100	100	100

Sentinel-2A uydu verisiyle yapılan DVM sınıflandırması sonucu yapılan doğruluk analizi incelendiğinde bitki indekslerinin dahil edildiği ve edilmediği sınıflandırmalarda doğruluk değerlerinin genelinin %90'm üzerinde olduğu görülmüştür.

Tablo 11. Sentinel-2A RO ve Sentinel-2A Bitki İndeksli RO sınıflandırma sonuçları için her bir sınıfa ait kullanıcı, üretici ve F-score doğruluk değerleri

Sentinel-2A RO				Sentinel-2A Bitki İndeksli RO			
Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)	Sınıflar	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	F-Score (%)
Hastalıklı	95.11	97.93	96.50	Hastalıklı	94.07	98.52	96.24
Sağlıklı	96.48	97.27	96.87	Sağlıklı	97.54	97.54	97.54
Yerleşim	48	88.88	73.53	Yerleşim	54.76	85.18	67.16
Elektrik Hattı	55.17	28.07	37.21	Elektrik Hattı	63.88	40.35	49.46
Yol	78.13	69.44	62.34	Yol	54.76	85.18	66.67


Sentinel-2A uydu verisiyle yapılan RO sınıflandırması sonucu yapılan doğruluk analizi incelendiğinde hastalıklı ve sağlıklı sınıfın hem bitki indekslerinin dahil edildiği hem de edilmediği sınıflandırmalarda doğruluk değerlerinin üretici, kullanıcı ve F-score doğruluğunda en yüksek doğruluk değerine sahip olduğu görülmüştür.

Tablo 12. Nesne tabanlı Sentinel-2A ve Landsat-8 Bitki İndeksli RO sınıflandırma sonuçları için genel doğruluk değerleri


NESNE TABANLI RASTGELE ORMAN SINIFLANDIRMA ALGORİTMASI(RO)	
Kombinasyon	Genel Doğruluk(%)
S2+NDVI+SAVI+TVI+RVI+NPCRI+EVI	93.5
L8+NDVI+SAVI+TVI+RVI+NPCRI+EVI	75

### 4.3. Zaman Serileri Grafiklerinin Analizi


Landsat-8 ve Sentinel-2A uydu verileriyle, epidemiyolojinin yaygın olduğu ekim ayı baz alınarak 2018-2021 yılları ekim ayları tarih aralığı olarak belirlenmiş ve orman sağlığını izlemek amacıyla hesaplanan bitki indekslerinin her biri için zaman serileri grafikleri oluşturulmuş ve  $r^2$  korelasyonu analiz edilmiştir. Landsat-8 uydu verisi kullanılarak hesaplanan bitki indeksleri zaman serisi grafiklerine Şekil 39-40-41-42-43 ve 44'te, Sentinel-2A uydu verisi kullanılarak hesaplanan bitki indeksleri zaman serisi grafiklerine Şekil 45-46-47-48-49 ve 50'de yer verilmiştir.




Şekil 39. Landsat-8 verileriyle NDVI zaman serisi grafiği




Şekil 40. Landsat-8 verileriyle EVI zaman serisi grafiği




Şekil 41. Landsat-8 verileriyle SAVI zaman serisi grafiği



Şekil 42. Landsat-8 verileriyle RVI zaman serisi grafiği




Şekil 43. Landsat-8 verileriyle TVI zaman serisi grafiği




Şekil 44. Landsat-8 verileriyle NPCRI zaman serisi grafiği


Landsat-8 verileriyle hesaplanan bitki indekslerinin zaman serileri grafikleri oluşturulup analiz edildiğinde ve  $r^2$  korelasyon değerleri yorumlandığı zaman genel olarak korelasyonların zayıf olduğu görülmüştür. En kötü korelasyon değeri NPCRI indeksi zaman serisi grafiğinde görülürken en yüksek korelasyon değeri SAVI indeksi zaman serisi grafiğinde görülmüştür. Buna rağmen tüm grafiklerdeki korelasyon değerleri en zayıf olarak yorumlanmaktadır. Veri setindeki aykırı değerler korelasyon katsayılarını etkilemektedir. Bununla beraber trend eğilimleri incelendiğinde NDVI, EVI, SAVI ve TVI grafiklerinin artan, RVI ve NPCRI grafiklerinin azalan trend eğilimi gösterdiği görülmüştür.




Şekil 45. Sentinel-2A verileriyle NDVI zaman serisi grafiği




Şekil 46. Sentinel-2A verileriyle EVI zaman serisi grafiği



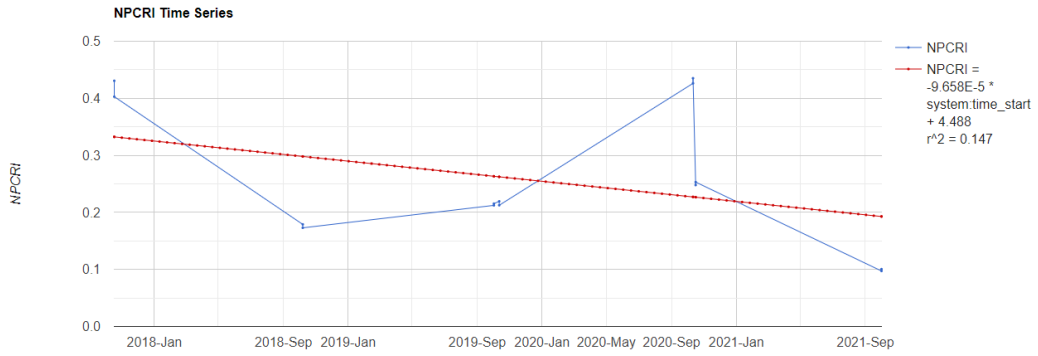
Şekil 47. Sentinel-2A verileriyle SAVI zaman serisi grafiği



Şekil 48. Sentinel-2A verileriyle RVI zaman serisi grafiği



Şekil 49. Sentinel-2A verileriyle TVI zaman serisi grafiği




Şekil 50. Sentinel-2A verileriyle NPCRI zaman serisi grafiği

Sentinel-2A verileriyle hesaplanan bitki indekslerinin zaman serileri grafikleri oluşturulup analiz edildiğinde ve  $r^2$  korelasyon değerleri yorumlandığı zaman genel olarak korelasyonların zayıf olduğu görülmüştür. En kötü korelasyon değeri NPCRI indeksi zaman serisi grafiğinde görülürken en yüksek korelasyon değeri EVI indeksi zaman serisi grafiğinde görülmüştür. Buna rağmen EVI ve SAVI indeksleri zaman serileri grafikleri hariç tüm grafiklerdeki korelasyon değerleri en zayıf olarak yorumlanırken EVI ve SAVI grafikleri orta olarak yorumlanmaktadır. Veri setindeki aykırı değerler korelasyon katsayılarını etkilemektedir. Bununla beraber trend eğilimleri incelendiğinde NDVI, EVI, SAVI ve TVI grafiklerinin artan, RVI ve NPCRI grafiklerinin azalan trend eğilimi gösterdiği görülmüştür.

#### 4.4. Sınıflandırma Sonuçları Alan Grafiklerinin Yorumlanması


Landsat-8 uydusuna ait uydu verileri, 2018 ve 2020 yıllarında bulutlu olduğu için bu uydu verisine ait sınıflandırma sonuçları sağlıklı olmadığından grafiğe eklenmemiştir. Sadece 2019 yılına ait hem DVM hem RO sınıflandırma sonuçlarına ait alan grafiğine yer verilmiştir.

Landsat DVM Sınıflandırması  
Alan Grafiği (ha)




■ Sağlıklı ■ Hastalıklı ■ Yol  
■ Elektrik Hattı ■ Yerleşim

Landsat RO Sınıflandırması  
Alan Grafiği (ha)

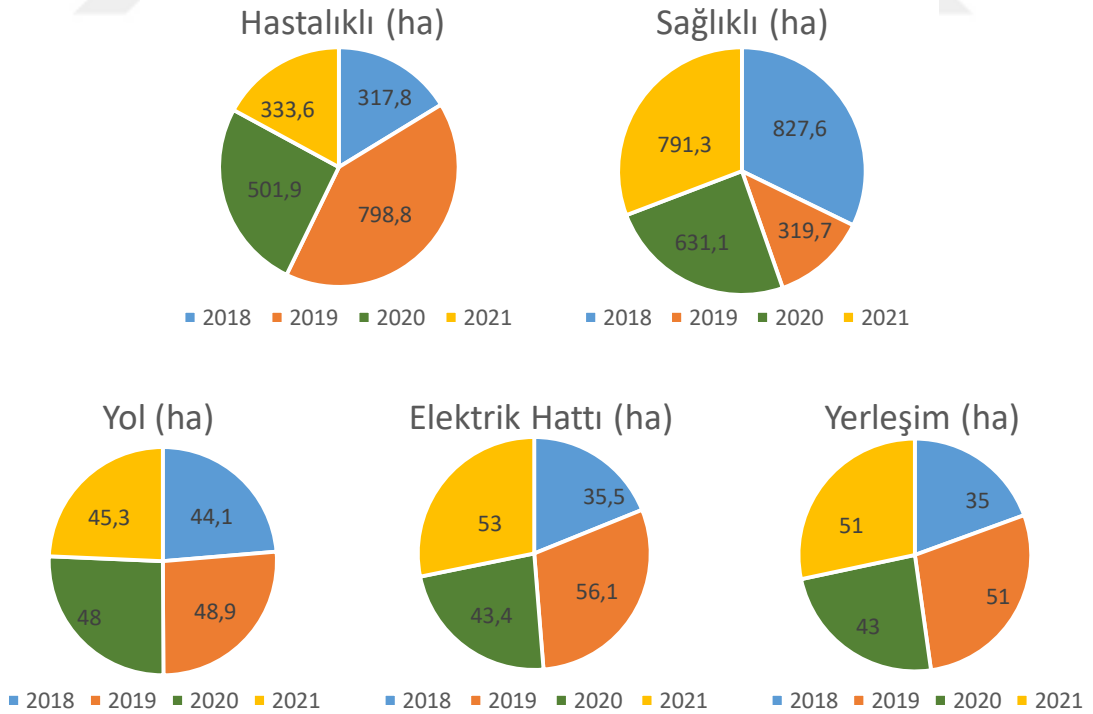


■ Sağlıklı ■ Hastalıklı ■ Yol  
■ Elektrik Hattı ■ Yerleşim

Şekil 51. Landsat-8 için piksel tabanlı DVM ve RO sınıflandırması sonucu her bir sınıfa ait alan miktarı (2019)



Şekil 52. Sentinel-2 için piksel tabanlı DVM sınıflandırması sonucu her bir sınıfa ait alan miktarı



Şekil 53. Sentinel-2 için piksel tabanlı RO sınıflandırması sonucu her bir sınıfa ait alan miktarı

Grafikler incelendiđi zaman hastalıklı alan miktarının diđer yıllara göre 2019 yılında arttığı sađlıklı alan miktarının da aynı yılda azaldığı görölmektedir. Bu grafikte orman sađlığının izlenmesinde diđer sonuçlarla aynı sonucu vermiş olup çalışmanın dođruluđunu ve güvenilirliğini ortaya koymaktadır.



## 5. SONUÇLAR VE ÖNERİLER

Kütahya-Domaniç, Bursa-İnegöl sınırında yer alan Tahtaköprü mevki içerisinde yer alan ormanlık alan için bulut tabanlı platformda 2017-2021 tarih aralığına ait Landsat-8 ve Sentinel-2A uydu görüntüleri kullanılarak kontrollü sınıflandırma yöntemleri ve zaman serisi analizleri ile orman sağlığı izlemesi yapılmıştır.

Çalışma sonucunda uydu verilerinin ve sınıflandırmaların sonuçları karşılaştırılmış olup orman sağlığını izlemek için hangi uydu verisinin ve sınıflandırma yönteminin daha etkili olduğuna karar verilmiştir.

Tahtaköprü çalışma alanını izlemek için bitki indekslerinden büyük ölçüde yardım alınmıştır. Çalışma alanına ait bitki indeksleri, zaman serisi grafiklerine dönüştürüldüğünde 2018 ve 2019 ekim aylarındaki ani azalışlar dikkat çekmekte olup bu tarihler üzerindeki uydu görüntülerine yoğunlaşmıştır. Bunun sonucunda 2018 ekim ayında orman sağlığının zararlılar tarafından etkilenmeye başladığı, 2019 yılında epidemiyeye neden olduğu ve 2020 yılında orman sağlığının iyileşmeye başladığı tespit edilmiştir.

Bu tarihler üzerindeki görüntüler, sınıflandırma yapma işleminde kullanılmıştır. Sınıflandırma işlemi sonucunda, RO yöntemi Sentinel-2A sınıflandırması için %90.34, Landsat-8 sınıflandırması için %85.70 genel doğruluk değerini vermiştir. Her iki uydu verisi için genel doğruluk değerleri yüksek olsa da Sentinel-2A uydu verileriyle yapılan sınıflandırma sonucu genel doğruluk oranı daha yüksektir. DVM yöntemi ile yapılan sınıflandırma sonucunda Sentinel-2A sınıflandırması genel doğruluk değerinin %97.78, Landsat-8 sınıflandırması genel doğruluk değerinin %75.90 olduğu görülmüştür. Yine DVM yöntemiyle yapılan sınıflandırmanın Sentinel-2A verileri için daha iyi bir tercih olduğu görülmüştür. Aynı zamanda Sentinel-2A verileriyle yapılan DVM sınıflandırmasının, RO sınıflandırmasından daha yüksek doğruluk değerine sahip olduğu Landsat-8 verileri için ise yapılan RO sınıflandırmasının DVM sınıflandırmasından daha yüksek doğruluk değerine sahip olduğu görülmüştür. Yani Sentinel-2A verileri ile DVM sınıflandırması, Landsat-8 verileri ile RO sınıflandırmasının yapılması çalışmadan elde edilen verimi artırmaktadır. sadece Sentinel-2A için iyiyken DVM yöntemi ile sınıflandırma her iki uydu verisi için de yüksek sonuç vermiştir.

Kullanıcının ve üreticinin doğruluğu incelendiği zaman Sentinel-2A verileri için DVM yönteminde genel olarak %100'e yakın doğruluk değerini vermesi DVM'nin RO'dan daha iyi bir tercih olduğunun göstergesidir. Yine Landsat-8 verileri içinde RO sınıflandırması genel doğruluk değerlerinin DVM sınıflandırmasından yüksek olması Landsat-8 için RO sınıflandırmasının daha iyi bir tercih olduğunun göstergesidir.

Bitki indekslerinin bir bant gibi kabul edilip uydu verisine eklenmesi sonucuyla yapılan sınıflandırmaların genel doğruluk oranlarının, bitki indekslerinin dahil edilmediği sınıflandırmalardan daha yüksek olduğu ve sınıflandırmada bitki indeksleri kullanımının katkısı gösterilmiştir.

Son olarak nesne tabanlı ve piksel tabanlı sınıflandırma yöntemleri kıyaslandığında, Sentinel-2A için bitki indekslerinin dahil edildiği nesne tabanlı RO sınıflandırmasının %93.5 genel doğruluk oranı ile aynı yöntemle ve verilerle sınıflandırılmış piksel tabanlı RO sınıflandırmasının %90.81 genel doğruluk oranından yüksek olması Sentinel-2A verileri için nesne tabanlı sınıflandırma yöntemlerinin daha güvenilir bir tercih olduğunu göstermektedir. Aynı zamanda bitki indekslerinin dahil edildiği Landsat-8 sınıflandırma yöntemleri kıyaslandığında, piksel tabanlı RO sınıflandırmasının genel doğruluk oranı %85.58 iken nesne tabanlı RO sınıflandırmasının genel doğruluk oranı %75 olarak tespit edilmiştir. Yani Landsat-8 verileri için piksel tabanlı sınıflandırma yönteminin daha güvenilir bir sonuç olduğunu söylemek mümkündür.

Bu tez çalışmasında, büyük veri depolanmalarının önüne geçmek, çok sayıda veri ile hızlı işlem, analiz yapmak ve orman sağlığını mümkün olan en hızlı şekilde izlemek ve tespit etmek amacıyla bulut tabanlı platform kullanılmıştır. Bu platformun kullanımının ve bu platformda gerçekleştirilen işlemlerin yaygınlaştırılmasıyla orman sağlığı izlemeleri hızlı bir şekilde gerçekleştirilecek, zaman ve maliyet açısından çok önemli katkılar sağlayacaktır. Orman yangınları, zararlılardan etkilenmiş orman alanları, ormansızlaşma ve daha nicesi izlenebilir, erken tespit edilerek erken müdahalede bulunulabilecek ve çok önemli katkılar sağlayacaktır.

Yapılacak olan çalışmanın önemine göre konumsal ve zamansal çözünürlüğü daha yüksek uydu verileri kullanılabilir. Hatta çalışmada kullanılan uydu verisi sayısı, bitki indeksi sayısı ve sınıflandırma yöntemleri genişletilerek daha kapsamlı, daha hızlı, daha erken tespit edilebilecek çalışmalar gerçekleştirilebilir.

## 6. KAYNAKLAR

- Abd El-Ghany, N.M., Abd El-Aziz, S.E., ve Marei, S.S., 2020. A review: application of remote sensing as a promising strategy for insect pests and diseases management. *Environ Sci Pollut Res* **27**, 33503–33515.  
[doi.org/10.1007/s11356020095172](https://doi.org/10.1007/s11356020095172)
- Acker, J.G., McMahon, E., Shen, S., Hearty, T. ve Casey, N., 2009. Time – series analysis of remotely – sensed SeaWIFS chlorophly in river – influenced coastal regions. *EARSel eProceedings*
- Akkartal, A., Türüdü, O., ve Sunar Erbek, F., 2005. Çok Zamanlı Uydu Görüntüleri ile Bitki Örtüsü Değişim Analizi. TMMOB Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı 28 Mart - 1 Nisan 2005, Ankara
- Aghlmand, M., Kalkan, K., Onur, M. İ., Öztürk, G. ve Ulutak, E., 2021. Google Earth Engine ile arazi kullanımı haritalarının üretimi . Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi , 10 (1) , 38-47 , 2021.
- Anwer, A., ve Singh, G., 2019. Geo-spatial Technology for Plant Disease and Insect Pest Management. *Bulletin of Environment, Pharmacology and Life Sciences*, 8(12), 01-12.
- Chen, S., Woodcock, C. E., Bullock, E. L., Arévalo, P., Torchinava, P., Peng, S., ve Olofsson, P. 2021. Monitoring temperate forest degradation on Google Earth Engine using Landsat time series analysis. *Remote Sensing of Environment*, 265, 112648.
- Congalton, R. 1991. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment* 37: 35-46.
- Cruz, J. A., Santos, J. A., and Blanco, A., 2020. Spatial Disaggregation Of Landsat-Derived Land Surface Temperature Over A Heterogeneous Urban Landscape Using Planetscope Image Derivatives, *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B5-2020, 115–122.
- Çetinkaya, B., ve Toz, G., 2007. Coğrafi Veri Seçim İşlemi Sonuçlarının Değerlendirilmesinde Hata Matrisinin Kullanımı. *İTÜDERGİSİ/d*, Cilt 6, Sayı5-6 (2007).
- Erbek, S., F., Ölmez Z., ve Avcı, U., D., Z., 2005. Artvin Yöresinde Ladin (*Picea Orientalis* L. Link.) Orman Alanlarında Böcek Zararlıları Nedeniyle Oluşan Tahribatin İzlenmesinde Uydu Görüntülerinin Kullanımı. Ladin Sempozyumu, KTÜ-Trabzon, Ekim 2005.

- Erdem, F. , Derinpınar, M. A. , Nasırzadehdızajı, R. , Oy, S. , Şeker, D. Z. & Bayram, B. (2018). Rastgele Orman Yöntemi Kullanılarak Kıyı Çizgisi Çıkarımı İstanbul Örneği . *Geomatik* , 3 (2) , 100-107 . DOI: 10.29128/geomatik.362179
- Fitzgerald G., 2000. Bug checking for mites—from the sky. *Australian Cotton Grower* 21(1):29–31
- Foody, G. M. 2001. GIS: the accuracy of spatial data revisited. *Progress in Physical Geography: Earth and Environment*, 25(3), 389–398.
- Mountrakis, G., Im, J., and Ogole, C., 2011 Support vector machines in remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.*, 66(3), 247–59, 2011. [doi.org/10.1016/j.isprsjprs.2010.11.001](https://doi.org/10.1016/j.isprsjprs.2010.11.001)
- Göktürk, T. ve Aksu, Y., 2005. Artvin İli Ormanlık Alanlarında Tespit Edilen *Calliteara pudibunda* (Linneaus, 1758)'nın (Lepidoptera; Lymantriidae) Morfolojisi, Biyolojisi ve Beslenme Özellikleri Üzerine Bir Araştırma. *Orman Mühendisliği*, Yıl:43, Sayı:Temmuz-Ağustos-Eylül, 34-35.
- Hart WG, Ingle SJ, Davis MR, Mangum C., 1973 Aerial photographywith infrared color film as a method of surveying for citrus blackfly.*J Econ Entomol* 66(1):190–194.<https://doi.org/10.1093/jee/66.1.190>
- Hart, W.G and Meyers, V.I., 1978. Infrared aerial color photography for detection of populations of brown soft scale in citrus groves. *Journal of Economic Entomology*. 61(3): 617–624.
- Peñuelas, J., Gamon, J.A., Fredeen, A.L., Merino, J., and Field, C.B., 1994 Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves, *Remote Sensing of Environment*, Volume 48, Issue 2, 1994, Pages 135-146, ISSN 0034-4257, [doi.org/10.1016/00344257\(94\)901368](https://doi.org/10.1016/00344257(94)901368).
- Karabacak, K., ve Yılmaz, E., 2012. Arazi Örtüsünün Kontrollü Sınıflandırılması Sırasında Karşılaşılan Sorunlar . *Tücaum V11. Coğrafya Sempozyumu* (pp.146). Ankara, Turkey
- Karaköse, M., Terzioğlu, S., Başkent, E.Z., ve Karahalil, U., 2013. Çamlıhemşin (Rize) Orman Planlama Biriminin Habitat Tiplerinin Tespiti ve Konumsal Değişimlerinin İzlenmesi (s. 1-10). *Çamlıhemşin Sempozyumu*, Rize.
- Kavzoğlu, T., & Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.

- Kavzoglu, T., ve Şahin, E.K., 2012. Bulut Bilişim Teknolojisi ve Bulut CBS Uygulamaları. 4. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu (UZALCBS'2012), 16-19 Ekim 2012, Zonguldak.
- Kaya, Y., ve Polat, N., 2021. Bitki İndeksleri Kullanarak Buğday Bitkisinin Rekolte Tahmini. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, c. 12, sayı. 1, ss. 99-110, Oca. 2021, doi:10.24012/dumf.860325
- Miller, J., 2016. Examining the Hansen Global Forest Change (2000 - 2014) dataset within an Australian local government area.
- Neteler, M., 2004. MODIS time series remote sensing for epidemiological modeling. International Symposium on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences.
- Ogata, S., Kirimoto, K. and Ide, M., 2002, Time series image analysis of Dalian, China by remote sensing, Trans. of the Society of Instrument and Control Engineers, 2099 – 2101.
- Oguz, H., 2017. Landsat 8 Uydu Görüntüsünden Otomatik Yer Yüzey Sıcaklığı Eldesi: Diyarbakır – Türkiye Örneği . Turkish Journal of Forest Science , 1 (1) , 33-43 . DOI: 10.32328/turkjforsci.296845.
- Özer, O.O. ve İlkdoğan, U., 2013. Box – Jenkins modeli yardımıyla dünya pamuk fiyatının tahmini. Tekirdağ Ziraat Fakültesi Dergisi, 10 (2), 13 – 20.
- Özen, M., 2013. Uzaktan algılama da Pikel ve Nesne Tabanlı Sınıflandırma, Sınıflandırma Sonuçlarının Değerlendirilmesi, Doğruluk Analizlerinin Yapılması ve CBS Ortamına Aktarımı Bülent Ecevit Üniversitesi Jeodezi ve Fotogrametri Mühendisliği, Ders Sunumu.
- Özlüer Başer, B. , Yangın, M. & Sarıdaş, E. S. (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması . Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi , 25 (1) , 112-120 . DOI: 10.19113/sdufenbed.842460
- Öztürk M., (2021). Python ile Sınıflandırma Analizleri – Rastgele Orman (Random Forest) Algoritması. <https://miracozturk.com/>. 18 Ocak 2023.
- Mantero, P., Moser, G., and Serpico S. B., 2005. Partially supervised classification of remote sensing images through SVM-based probability density estimation. IEEE Trans. Geosci. Remote Sens., 43(3), 559–70, 2005. [doi.org/10.1109/TGRS.2004.842022](https://doi.org/10.1109/TGRS.2004.842022)
- Piwowar, J.M., ve Ledrew, E.F., 2002. ARMA time series modeling of remote sensing imagery: a new approach for climate change studies. International Journal of Remote Sensing, 24, 5225 – 5248.

- Prabhakar, M., Prasad, Y.G., Thirupathi, M., Sreedevi, G., Dharajothi, B., and Venkateswarlu, B., 2011. Use of ground based hyperspectral remotesensing for detection of stress in cotton caused by leafhopper(Hemiptera: Cicadellidae). *Comput Electron Agric* 7(9):189–198. [doi.org/10.1016/j.compag.2011.09.012](https://doi.org/10.1016/j.compag.2011.09.012)
- Rullan-Silva, C., Olthoff, A., Delgado de la Mata, J., and Pajares-Alonso, J., 2013. Remote Monitoring of Forest Insect Defoliation -A Review-. *Forest Systems*, 22(3), 377-391. [doi.org/10.5424/fs/201322304417](https://doi.org/10.5424/fs/201322304417)
- Sabuncu, A., ve Sunar, F., 2017. Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: Van-Erciş Depremi Örneği . *Doğal Afetler ve Çevre Dergisi* , 3 (1) , 1-8 . DOI: 10.21324/dacd.271091
- Sarıkaya, O., Örucü, Ö. K., Şen, İ.ve Açıcı, Ö., 2019. Türkiye Kayın Ormanları İçin Yeni Bir Tehdit Kızıl Kuyruklu Kayın Tırtılı [Calliteara pudibunda(Linneaus, 1758)]'nın Günümüz ve Gelecekteki Potansiyel Yayılış Alanlarının Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (17), 58-65.
- Sarıkaya, O., Kadioğulları, A.İ., & Açıcı, Ö., 2021. İnegöl (Bursa) ve Domanıç (Kütahya) Yöresi Doğu Kayını (Fagus orientalisLipsky) Ormanları İçin Önemli Bir Tehdit: Kızılkuyruklu Kayın Tırtılı -Calliteara pudibunda(Linneaus, 1758). *Avrupa Bilim ve Teknoloji Dergisi*, (21), 131-135.
- Sarıyılmaz, F. B., 2012. Zaman Serileri ile Değişim Analizi: İstanbul, Sarıyer Örneği, Yüksek Lisans tezi, İTÜ, Fen Bilimleri Enstitüsü, İstanbul, 2012.
- Sarıyılmaz, F. B. , ve Musaoğlu, N., 2014. Zaman Serilerinin Değişim Analizlerinde Kullanımı İstanbul sarıyer örneği . UZ-AL CBS Kongresi.
- Selim, B., 2018. R Programlama Serisi -6 Korelasyon,Regresyon ve Zaman Serisi Analizleri
- Soydan, O., ve Benliay, A. 2020, Kentsel Alanlardaki Bitki Örtüsünün Belirlenmesinde Yapay Sinir Ağları ve Uzaktan Algılama Teknolojilerinin Kullanımı. II. International Applied Social Sciences Congress (C-IASOS). Online Journal of Art and Design volume 8, issue 4, October 2020
- Sudha Rani, D., Venkatesh, M.N., Naga Satya Sri, Ch., and Anand Kumar, K., 2018. Remote Sensing as Pest Forecasting Model in Agriculture. *Int.J.Curr.Microbiol.App.Sci.* 7(3):2680-2689. [doi.org/10.20546/ijemas.2018.703.310](https://doi.org/10.20546/ijemas.2018.703.310)
- Şentürk, Ü. G., (2020),Uzaktan Algılama Teknikleri Kullanılarak Kayısı Bahçelerinin Tespiti Ve Rekolte Tahmini; Malatya Battalgazi Örneği. Yüksek Lisans Tezi, NEÜ, Fen Bilimleri Enstitüsü, Konya, 2020.

Taşçı, İ., (2018) Orta Çözünürlüklü Uydu Görüntüleri Kullanarak Yanmış Orman Alanlarının Farklı Sınıflandırma Yöntemleri İle Haritalanması. Yüksek Lisans Tezi, AÜ, Fen Bilimleri Enstitüsü, Eskişehir, 2018.

URL-1, <https://ogm.gov.tr/tr/ormanlarimizsitesi/TurkiyeOrmanVarligi/Haritalar/>. 27 Kasım 2022.

URL- 2, [https:// ktu.edu.tr/dosyalar/ormankoruma\\_e2818.pdf](https://ktu.edu.tr/dosyalar/ormankoruma_e2818.pdf) . 27 Kasım 2022.

URL- 3, <http://kutahya.gov.tr/kizil-kuyruklu-kayin-tirtili-hakkinda-basin-aciklamasi>. 27 Kasım 2022.

URL-4, <https://haritaonline.blogspot.com> 25 Kasım 2022.

URL-5, <https://docplayer.biz.tr>. 26 Kasım 2022.

URL-6, <http://muratsakal.com/> . 26 Kasım 2022.

URL-7, <https://slideplayer.biz.tr/slide/2021539/> 26 Kasım 2022.

URL-8, <https://earthengine.google.com/platform/>. 18 Ocak 2022.

URL-9, <https://tr.wikipedia.org/wiki/Uydu>. 29 Kasım 2022.

URL- 10, [http://www.nik.com.tr/content\\_sistem\\_uydu.asp](http://www.nik.com.tr/content_sistem_uydu.asp). 29 Kasım 2022.

Yakut, E., Elmas, D., ve Yavuz, Y., 2014. Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini . Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi , 19 (1) , 139-157 .

Yaman, Ş., ve Tunç Görmüş, E., 2022. Orman Zararlılarının Verdiği Zararın Google Earth Engine Kullanılarak İzlenmesi . Turkish Journal of Remote Sensing and GIS , 3 (2) , 139-149 . DOI: 10.48123/rsgis.1116907

Yıldız, H., Mermer, A., Ünal, E. ve Akbaş, F., 2012. Türkiye Bitki Örtüsünün NDVI Verileri ile Zamansal ve Mekansal Analizi . Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi , 21 (2) , 50-56 .

Yılmaz İ., ve Öztürk, D., 2019. Samsun-Atakum Orman Alanlarının Belirlenmesinde Farklı Bitki İndekslerinin Karşılaştırılması. International Journal of Multidisciplinary Studies and Innovative Technologies, 3 (1), 9-13, 2019.

Z B Wang et al 2014 IOP Conf. Ser.: Earth Environ. Sci. 17 012254

Zhang, T., Su, J., Liu, C., Chen, W.H., 2017, Band Selection in Sentinel-2 Satellite for Agriculture Applications, Proceedings of the 23rd International Conference on Automation & Computing, University of Huddersfield, Huddersfield, UK, 7-8 September 2017.

Zhou, Z., Zang, Y., Zhao, Z., Luo, X and Zhou, X., 2010. Canopy hyper spectral reflectance features of rice caused by rice brown planthopper (*Nilaparvatalugens*) infestation. American Society for Agriculture and Biological Engineering, Pittsburgh, Pennsylvania, June 20 -June 23, 2010



## ÖZGEÇMİŞ

Şule YAMAN, İlkokul ve orta öğrenimini Akçaabat Merkez İlkokulu'nda, lise öğrenimini Trabzon Kanuni Anadolu Lisesi'nde tamamlamıştır. 2020 yılında Karadeniz Teknik Üniversitesi Mühendislik Fakültesinden Harita Mühendisi olarak mezun olmuştur. 2020-2021 eğitim öğretim yılında Karadeniz Teknik Üniversitesi Harita Mühendisliği Ana Bilim Dalında yüksek lisans öğrenimine başlamıştır. İngilizce bilmektedir.

Yaman, Ş. & Tunç Görmüş, E. (2022). Orman Zararlılarının Verdiği Zararın Google Earth Engine Kullanılarak İzlenmesi . Turkish Journal of Remote Sensing and GIS , 3 (2) , 139-149 . DOI: 10.48123/rsgis.1116907

Yaman, Ş., Tanır Kayıkçı E., ve Tunç Görmüş, E. (2022). NDVI Ve Yağış Arasındaki İlişkinin GEE'de Zaman Serisi Yöntemi İle Analizi: Rize İli Örneği. 6. Geleceğin Mühendisleri Uluslararası Öğrenci Sempozyumu. 1-2 Temmuz 2022. Zonguldak. 260-264

Yaman, Ş. & Tunç Görmüş, E. (2022). Monitoring of Forest Pest Insect Through Remote Sensing Time Series Analysis: Example Of Tahtakopru Province. 4th International Forest Entomology and Pathology Symposium (ENFITO 2022). 12-14 Mayıs 2022. Trabzon. 35

Yaman, Ş. & Tunç Görmüş, E. (2022). Monitoring of Forest Pest Insect Through Remote Sensing Time Series Analysis: Example Of Tahtakopru Province. 4th International Forest Entomology and Pathology Symposium (ENFITO 2022). 12-14 Mayıs 2022. Trabzon. 7-15