



**GIDA GÜVENLİĞİ BAĞLAMINDA COĞRAFİ BİLGİ
TEKNOLOJİLERİNDEN YARARLANILMASI:
MANİSA ÖRNEKLEMİNDE TARIMSAL
ÜRÜNLERİN PARSEL BAZLI TESPİT EDİLMESİ**

Doktora Tezi

İbrahim TAŞCI

Eskişehir 2024

**GIDA GÜVENLİĞİ BAĞLAMINDA COĞRAFI BİLGİ
TEKNOLOJİLERİNDEN YARARLANILMASI: MANİSA ÖRNEKLEMİNDE
TARIMSAL ÜRÜNLERİN PARSEL BAZLI TESPİT EDİLMESİ**

İbrahim TAŞCI

Doktora Tezi

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Prof. Dr. Alper ÇABUK

(İkinci Danışman: Dr. Öğr. Üyesi Resul ÇÖMERT)

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ocak 2024

JÜRİ VE ENSTİTÜ ONAYI

İbrahim TAŞCI'nın GIDA GÜVENLİĞİ BAĞLAMINDA COĞRAFİ BİLGİ TEKNOLOJİLERİNDEN YARARLANILMASI: MANİSA ÖRNEKLEMİNDE TARIMSAL ÜRÜNLERİN PARSEL BAZLI TESPİT EDİLMESİ başlıklı çalışması 16/01/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim dalında Doktora Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof.Dr. Alper ÇABUK

Üye

: Prof.Dr. Saye Nihan ÇABUK

Üye

: Prof. Dr. Hakan A. NEFESLİOĞLU

Üye

: Doç.Dr. Cem SAYIN

Üye

: Doç.Dr. Mehmet ÇETİN

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Doktora đrencisi İbrahim TAřCI, GIDA GVENLİđİ BAđLAMINDA COđRAFİ BİLGİ TEKNOLOJİLERİNDEN YARARLANILMASI: MANİSA RNEKLEMİNDE TARIMSAL RNLERİN PARSEL BAZLI TESPİT EDİLMESİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımda incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı
Prof. Dr. Alper ABUK

ÖZET

GIDA GÜVENLİĞİ BAĞLAMINDA COĞRAFI BİLGİ TEKNOLOJİLERİNDEN YARARLANILMASI: MANİSA ÖRNEKLEMİNDE TARIMSAL ÜRÜNLERİN PARSEL BAZLI TESPİT EDİLMESİ

İbrahim TAŞCI

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

Danışman: Prof. Dr. Alper ÇABUK

(İkinci Danışman: Dr. Öğr. Üyesi Resul ÇÖMERT)

Gıda güvenliğinin en temel halkası olan tarımsal üretim, tarım alanlarının izlenmesi ve yönetimi için CBS ve uzaktan algılama teknolojileri önemli katkı sunmaktadır. Tarım ürünlerinin tespit edilmesi, sınıflandırılması ve bitki deseninin oluşturulması için mekânsal, spektral, zamansal karakteristik yönleri ile birbirine üstün olan birçok uydu görüntüsü bulunmaktadır. Sentinel-2 gibi çok bantlı ve spektral çözünürlüğü yüksek uydu görüntüleri zamansal ve mekânsal olarak yetersiz kalabilmektedir. Farklı uydulara ait görüntülerin belirli kurallar çerçevesinde keskinleştirmesi hedef çalışmanın hassasiyetini artırdığı öngörülmektedir. Bu çalışmada, günümüzde tarım alanlarını izlemede aktif kullanılan S2 ve PS uydu görüntülerinin füzyon edilmesi ve keskinleştirilmiş görüntünün ürün sınıflandırmada kullanımı incelenmektedir. Türkiye'nin tarımsal ürün ihtiyacının yaklaşık %10'unu karşılayan Gediz Havzası sınırlarındaki Manisa ilinde Domates, Mısır, Pamuk, Üzüm ve Zeytin ürünlerinin tespiti ve sınıflandırılması hedeflenmiştir. Çalışmada DVM, XGBoost, RO ve KNN olmak üzere dört sınıflandırma algoritması kullanılmıştır. Aynı veri tabanı, sınıflandırma indeksleri ve makine öğrenme algoritmaları üzerinden S2, PS ve füzyon görüntü ayrı ayrı sınıflandırmaya alınmıştır. Sınıflandırma parsel bazlı yapılmıştır ve ÇKS kayıtları yersel veri olarak kullanılmıştır. Füzyon görüntü diğer görüntülerden daha başarılı sonuç vermiştir. En yüksek doğruluklu sonuçları 87,05% genel doğruluk ve 0,82 kappa değeri ile DVM ve 85,09% genel doğruluk ve 0,80 kappa değeri ile XgBoost algoritmaları vermiştir ve bu sonuçlar istatistiksel olarak anlamlıdır.

Anahtar Sözcükler: CBS, Uzaktan algılama, Sentinel, Planet Scope, Görüntü füzyonu.

ABSTRACT

USING GEOGRAPHICAL INFORMATION TECHNOLOGIES IN THE CONTEXT OF FOOD SECURITY: PARCEL-BASED DETERMINATION OF AGRICULTURAL PRODUCTS IN MANISA SAMPLE

İbrahim TAŞCI

Department of Remote Sensing and Geographical Informational System
Eskişehir Technical University, Institute of Graduate Programs, January 2024

Supervisor: Prof. Dr. Alper ÇABUK
(Co-Supervisor: Asst. Prof. Dr. Resul ÇÖMERT)

Geographic information systems and remote sensing technologies make a significant contribution to agricultural production, which is the most basic link of food security, and to monitoring and management of agricultural areas. Many satellite images are superior to each other with their spatial, spectral and temporal characteristics for detecting and classifying agricultural products and creating plant patterns. Multispectral and high spectral resolution satellite images such as Sentinel-2 may be insufficient temporally and spatially. It is envisaged that sharpening the images of different satellites within the framework of certain rules increases the sensitivity of the target study. This study examines the fusion of Sentinel-2 and Planet Scope satellite images, which are actively used in monitoring agricultural fields today, and the use of the sharpened image in product classification. It is aimed to detect and classify Tomato, Corn, Cotton, Grape and Olive products in Manisa province, within the borders of the Gediz Basin, which meets approximately 10% of Turkey's agricultural product needs. Four classification algorithms were used in the study: SVM, XGBoost, RO and KNN. Sentinel-2, Planet Scope and fusion images were classified separately using the same database, classification indexes and machine learning algorithms. Classification was made on a parcel basis and ÇKS records were used as terrestrial data. The fusion image gave better results than other images. SVM gave the highest accuracy results with 87.05% overall accuracy and 0.82 kappa value, and XgBoost algorithms with 85.09% overall accuracy and 0.80 kappa value, and these results are statistically significant.

Keywords: GIS, Remote sensing, Sentinel, Planet Scope, Pansharpening.

TEŞEKKÜR

Tez çalışmam boyunca bilgi ve desteğini esirgemeyen, tecrübelerini motive ederek aktaran sevgili hocam Prof. Dr. Alper ÇABUK, Dr. Öğr. Üyesi Resul ÇÖMERT'e, Yer ve Uzay Bilimleri Enstitüsü hocalarına, çalışanlarına ve öğrenci arkadaşlarıma, tez sürecinde getirdiği yapıcı eleştirilerle tezin şekillenmesine büyük katkıda bulunan sevgili hocam Prof. Dr. Saye Nihan ÇABUK'a ve yaptıkları katkılar ve iyi niyetleri için Doç.Dr.Cem Sayın'a, teşekkür ederim.

Ders ve tez sürecinde hoşgörü, sabır ve sevgisini eksik etmeyen sevgili eşim Şehadet TAŞCI özelinde hayatım boyunca maddi manevi desteklerini sürekli hissettiğim tüm aileme şükranlarımı ve teşekkürlerimi sunarım.

İbrahim TAŞCI

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

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

İbrahim TAŞCI

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER	VIII
TABLOLAR DİZİNİ.....	XII
ŞEKİLLER DİZİNİ.....	XIV
GÖRSELLER DİZİNİ	XVI
SİMGELER VE KISALTMALAR DİZİNİ.....	XVIII
1. GİRİŞ	1
1.1. Tezin Amacı	6
1.2. Tezin Kapsamı.....	6
1.2.1. Mekânsal kapsam	6
1.2.2. Zamansal kapsam.....	9
1.2.3. Veri kapsamı	9
1.3. Hipotez	9
1.4. Araştırma Soruları.....	10
1.5. Tezin Sınırlılıkları	10
2. KURAMSAL TEMELLER	11
2.1. Gıda Güvenliği, Uzaktan Algılama ve CBS İlişkisi.....	11
2.2. Tarım Alanlarının Uzaktan Algılama Yöntemleri ile İzlenmesi	12
2.3. Uzaktan Algılamanın Temelleri.....	13
2.4. Elektromanyetik Enerjiye Atmosferik Etkiler	17

2.4.1. Bitkilerin spektral yansması.....	19
2.4.1.1. Tarım bitkilerinin spektral yansması.....	21
2.4.2. Toprağın spektral yansması.....	22
2.5. Uzaktan Algılama Sistemleri.....	22
2.5.1. Uzaktan algılama verilerinin elde edilmesi.....	24
2.5.2. Algılayıcı tipleri.....	25
2.6. Uyduların yörüngeleri ve tarama alanı.....	25
2.7. Veri işleme ve görsel yorumlama.....	27
2.7.1. Radyometrik çözünürlük.....	28
2.7.2. Spektral çözünürlük.....	29
2.7.2.1. Mekânsal çözünürlük.....	29
2.7.3. Zamansal çözünürlük.....	29
2.8. Görüntü elde etme.....	30
2.8.1. Ön işleme.....	30
2.8.2. Geometrik düzeltme.....	30
2.8.3. Radyometrik düzeltme.....	31
2.8.4. Görüntü keskinleştirme (Pansharpening).....	32
2.8.4.1. HPF (High Pass Filter) keskinleştirme yöntemi.....	33
2.8.4.2. P+XS keskinleştirme yöntemi.....	33
2.9. Yer gözlem uydu sistemleri.....	34
2.9.1. Sentinel-2.....	35
2.9.1.1. Uydu teknik özellikleri.....	36
2.9.1.2. Spektral çözünürlük.....	37
2.9.1.3. Radyometrik çözünürlük.....	38
2.9.1.4. Veri formatı.....	39
2.9.2. Planet Scope.....	40
2.10. İndeksler.....	41
2.10.1. Normalize edilmiş fark bitki indeksi (NDVI).....	41
2.10.2. Fark bitki indeksi (DVI).....	42
2.10.3. Toprakla dengelenmiş bitki indeksi (SAVI).....	42
2.10.4. Basit oran indeksi (SR).....	43
2.10.5. Gelişmiş bitki örtüsü indeksi (EVI).....	43
2.10.6. Dönüştürülmüş bitki örtüsü indeksi (TVI).....	44

2.10.7. Yansımada modifiye edilmiş klorofil emilim indeksi (MCARI)	44
2.10.8. Üçgensel Klorofil indeksi (TCI)	44
2.10.9. Diğer İndeksler	44
2.11. Sınıflandırma	45
2.11.1. Piksel tabanlı sınıflandırma.....	47
2.11.1.1. <i>Kontrolsüz sınıflandırma</i>	47
2.11.1.2. <i>Kontrollü sınıflandırma</i>	48
2.11.2. Nesne tabanlı sınıflandırma.....	49
2.11.3. Sınıflandırma algoritmaları.....	50
2.11.3.1. <i>En yakın komşuluk sınıflandırma algoritması</i>	51
2.11.3.2. <i>Rastgele orman algoritması</i>	52
2.11.3.3. <i>Destek vektör makinaları sınıflandırma yöntemi</i>	53
2.11.3.4. <i>XGBoost sınıflandırma yöntemi</i>	54
2.11.4. Doğruluk analizi	56
2.11.4.1. <i>Hata matrisi</i>	57
2.11.4.2. <i>Kappa istatistiği</i>	58
3. MATERYAL YÖNTEM	59
3.1. Uygulama İş Akışı	59
3.2. Veri Setlerinin Hazırlanması	60
3.2.1. Uydu görüntülerinin hazırlanması	60
3.2.2. Parsel verilerinin hazırlanması	62
3.2.3. Görüntü keskinleştirme (Pan Sharpening)	71
3.2.4. Bitki İndekslerinin Hesaplanması.....	74
3.2.5. Eğitim ve test veri setlerinin oluşturulması	76
4. ARAŞTIRMA BULGULARI.....	79
4.1. Makine Öğrenme Algoritmalarıyla Model Geliştirme ve Test.....	79
4.1.1. Rastgele orman (RO) algoritmalarının çalıştırılması	79
4.1.1.1. <i>RO ile Sentinel-2 sonuçları</i>	81
4.1.1.2. <i>RO ile Planet Scope sonuçları</i>	84
4.1.1.3. <i>RO ile Pan-Keskinleştirme sonuçları</i>	87
4.1.2. Destek vektör makinaları (DVM) algoritmasının çalıştırılması	90
4.1.2.1. <i>DVM ile Sentinel-2 sonuçları</i>	90

4.1.2.2. DVM ile Planet Scope sonuçları	93
4.1.2.3. DVM ile Pan-Keskinleştirme sonuçları	96
4.1.3. En yakın komşuluk (KNN) algoritması ile tahminleme.....	99
4.1.3.1. KNN ile Sentinel-2 sonuçları	99
4.1.3.2. KNN ile Planet Scope sonuçları.....	102
4.1.3.3. KNN Pan-Keskinleştirme sonuçları.....	105
4.1.4. XGBoost algoritmalarının çalıştırılması	108
4.1.4.1. XGBoost ile Sentinel-2 sonuçları.....	108
4.1.4.2. XGBoost ile Planet Scope sonuçları	111
4.1.4.3. Xgboost ile Pan-Keskinleştirme sonuçları.....	114
4.2. Algoritmalarının Karşılaştırılması	117
5. ARAŞTIRMA SONUÇLARI.....	122
5.1. Parsel Bazlı Ürün Tespiti	122
5.2. Sınıflandırma Algoritmaları ve Veri Setleri	123
5.3. Gıda Güvenliği Açısından Tarımsal Ürün Tespiti	126
6. TARTIŞMA VE ÖNERİLER	127
KAYNAKÇA	131
EKLER	
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Elektromanyetik dalga tiplerinin kullanım ve etkileri	17
Tablo 2.2. S2 bantlarının keskinleştirilmesinde pankromatik bant olarak kullanılan PS bantları	34
Tablo 2.3. Sentinel-2 10 m, radyometrik çözünürlük ve bant genişlikleri.....	38
Tablo 2.4. Sentinel-2 60 m, radyometrik çözünürlük ve bant genişlikleri.....	38
Tablo 2.5. Sentinel-2 20 m, radyometrik çözünürlük ve bant genişlikleri.....	39
Tablo 2.6. PS mekânsal çözünürlük ve bant dalga boyları	40
Tablo 2.7. PS ürün özellikleri	41
Tablo 2.8. Temel indeksler ve formülleri.....	45
Tablo 2.9. Sınıflandırma tahminlerinin değerlendirilmesi.....	57
Tablo 4.1. RO sınıflandırıcının S2 test parsellerinde tahminleme sonuçları	82
Tablo 4.2. RO sınıflandırıcının PS test parsellerinde tahminleme sonuçları	85
Tablo 4.3. RO sınıflandırıcının Pan-Keskinleştirme test parsellerinde tahminleme sonuçları	88
Tablo 4.4. Gamma:0.1, Cost:4 değişken değerleri ile sınıflandırma sonucu	91
Tablo 4.5. Gamma:0.3, Cost:16 değişken değerleri ile sınıflandırma sonucu	94
Tablo 4.6. Gamma:0.1, Cost:16 değişken değerleri ile sınıflandırma sonucu	97
Tablo 4.7. K=7 değişken değerleri ile sınıflandırma sonucu	100
Tablo 4.8. K=11 Değişken değerine göre KNN ile Planet Scope test verisi tahminleme sonuçları	103
Tablo 4.9. k=9 değişken değerleri ile sınıflandırma sonucu	106
Tablo 4.10. XGBoost algoritması ile S2 test alanı sonuçları (eta:0,04; iterasyon: 254)	109
Tablo 4.11. eta:0,01; max.depth:4; iterasyon 24 parametrelili sınıflandırma sonucu	112
Tablo 4.12. İterasyon 34, eta: 0.3 eta:0,05; depth:6 parametrelili sınıflandırma sonucu	115
Tablo 4.13. Domates ürüne ait doğruluk metrikleri	117
Tablo 4.14. Mısır ürüne ait doğruluk metrikleri	118
Tablo 4.15. Pamuk ürününe ait doğruluk metrikleri	119
Tablo 4.16. Üzüm ürününe ait doğruluk metrikleri	120
Tablo 4.17. Zeytin ürününe ait doğruluk metrikleri.....	120
Tablo 4.18. Tüm görüntü ve tüm algoritma sonuçlarını içeren genel doğruluk sonuç tablosu.....	121

Tablo 4.19. Tüm görüntü ve tüm algoritma sonuçlarını içeren kappa sonuç tablosu	121
Tablo 5.1. Üç farklı veri setine uygulanan dört makine öğrenme algoritması için geliştirilen sınıflandırıcı modellerin McNemar testi sonuçları	125



ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Gediz Havzasını oluşturan illerin havza içerisine giren alanları (%).....	8
Şekil 2.1. Elektromanyetik salınım.....	13
Şekil 2.2. Elektromanyetik Spektrum.....	15
Şekil 2.3. Elektromanyetik ışıınım	16
Şekil 2.4. Cisimlerin spektral yansıması	18
Şekil 2.5. Bitkilerin spektral yansıması	20
Şekil 2.6. Klorofil spektral yansıması	20
Şekil 2.7. Uyduların yörünge tipleri	26
Şekil 2.8. Görüntü piksel değerleri	27
Şekil 2.9. Görüntü piksel yoğunluğu	28
Şekil 2.10. Mekânsal çözünürlük	29
Şekil 2.11. Geometrik düzeltme	30
Şekil 2.12. PS ve S2 bantlarının spektral çözünürlüğü ve dalga boyu aralığı.....	37
Şekil 2.13. DVM algoritma prensibi	53
Şekil 2.14. DVM iki sınıfın ayrımı.....	54
Şekil 3.1. Tez çalışması kapsamında uygulana iş akışı şeması	59
Şekil 3.2. Yaz bitkilerinin spektral imzaları	62
Şekil 4.1. S2 veri seti için geliştirilen RO sınıflandırıcının optimum parametre seçimi	81
Şekil 4.2. PS veri seti için geliştirilen RO sınıflandırıcının optimum parametre seçimi	84
Şekil 4.3. Pan-Keskinleştirme veri seti için geliştirilen RO sınıflandırıcının optimum parametrelerinin belirlenmesi	87
Şekil 4.4. Sentinel-2 veri seti için optimum C ve gamma parametresinin belirlenmesi.....	91
Şekil 4.5. PS veri seti için optimum C ve gamma parametresinin belirlenmesi.....	93
Şekil 4.6. DVM ile Pan-Keskinleştirme veri seti için optimum gamma ve C parametrelerinin seçimi.....	96
Şekil 4.7. KNN algoritması ile S2 eğitim veri setinden geliştirilen sınıflandırıcı için en iyi K değerinin seçilmesi.....	99
Şekil 4.8. Planet Scope veri seti için en uygun K değerinin belirlenmesi.....	102
Şekil 4.9. Planet Scope veri seti için en uygun K değerinin belirlenmesi.....	105
Şekil 4.10. S2 eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi.....	108

Şekil 4.11. PS eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi	111
Şekil 4.12. S2 eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi	114



GÖRSELLER DİZİNİ

	<u>Sayfa</u>
Görsel 1.1. Ülke ve Manisa ili ölçeğinde çalışma alanı haritası	7
Görsel 1.2. Gediz Havza sınırları ve kapladığı iller	8
Görsel 2.1. Sağlıklı bitkilerdeki yansıma	19
Görsel 2.2. Algılayıcı tipleri.....	25
Görsel 2.3. Radyometrik çözünürlük	28
Görsel 2.4. Yer kontrol noktası	31
Görsel 2.5. Radyometrik düzeltme-2	32
Görsel 2.6. Sentinel-2 yapım aşaması	36
Görsel 2.7. Sentinel-2 uzay aracının şematik görünümü	36
Görsel 2.8. Uydu görüntülerinin NDVI görünümü	42
Görsel 3.1. Çalışma alanında yetiştirilen tarım ürünlerinin ekim-hasat zamanları.....	61
Görsel 3.2. Bir kadastro parseli içerisinde ekili farklı ürünler	64
Görsel 3.3. Mısır ekili olan parseldeki domates kaydı.....	65
Görsel 3.4. Boş tarım arazisindeki hatalı kayıtlar	66
Görsel 3.5. Doğru kayıt fakat bölünmesi gereken geometri	67
Görsel 3.6. Doğru kayıt çalışmada kullanılamayan sera alanı	67
Görsel 3.7. Doğru kayıt çalışmada kullanılamayan zeytin fabrika alanı	68
Görsel 3.8. Farklı nedenlerden dolayı sınırları değişen parsellerin sınırlarının düzeltilmesi	69
Görsel 3.9. Küçültülmüş tampon poligonları	70
Görsel 3.10. 1000 m ² altındaki tarım alanları	70
Görsel 3.11. S2 Bant 7'nin farklı çözünürlükte ve Planet ile keskinleştirilmiş görüntüleri.....	73
Görsel 3.12. Aynı alana ait S2 ve PS kırmızı bant ve keskinleştirilmiş pan görüntü	74
Görsel 4.1. R Studio RO kodları ve veri seti örneği	80
Görsel 4.2. RO sınıflandırıcı ile S2 test veri setinden tahminlenen parseller	83
Görsel 4.3. RO sınıflandırıcı ile PS test veri setinden tahminlenen parseller	86
Görsel 4.4. RO sınıflandırıcı ile Pan-Keskinleştirme test veri setinden tahminlenen parseller	89
Görsel 4.5. R Studio SVM Kodları ve Veri Seti	90
Görsel 4.6. DVM Sınıflandırıcısının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları	92
Görsel 4.7. DVM Sınıflandırıcısının PS test veri setine uygulanması ile tahmin edilen parsel sınıfları	95

Görsel 4.8. DVM Sınıflandırıcının Pan-Keskinleştirme test veri setine uygulanması ile tahmin edilen parsel sınıfları	98
Görsel 4.9. KNN-Sınıflandırıcının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları	101
Görsel 4.10. KNN-Sınıflandırıcının PS test veri setine uygulanması ile tahmin edilen parsel sınıfları	104
Görsel 4.11. KNN-Sınıflandırıcının Pan-Keskinleştirme test veri setine uygulanması ile tahmin edilen parsel sınıfları	107
Görsel 4.12. Xgboost sınıflandırıcının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları	110
Görsel 4.13. Xgboost sınıflandırıcının Planet test veri setine uygulanması ile tahmin edilen parsel sınıfları	113
Görsel 4.14. Xgboost sınıflandırıcının Pan-Keskinleştirme test veri setine uygulanması ile tahmin edilen parsel sınıfları	116

SİMGELER VE KISALTMALAR DİZİNİ

CBS	: Coğrafi Bilgi Sistemleri
UA	: Uzaktan Algılama
PS	: Planet Scope
S2	: Sentinel-2
RO	: Rastgele Orman
DVM	: Destek Vektör Makinaları
KNN	: En Yakın Komşuluk
ESA	: Avrupa Uzay Ajansı
CORINE	: Çevresel Bitki Koordinasyonu
NIR	: Yakın Kızılötesi Yansıma
R	: Kırmızı Bant
G	: Yeşil Bant
B	: Mavi Bant
PAN	: Panchromatic görüntü
MS	: Multispectral image (Çok bantlı görüntü)
GPS	: Global Konumlandırma Sistemi

1. GİRİŞ

Bugün 7,9 milyar olan Dünya nüfusunun 2050 yılına kadar 9,8 milyara hatta 2100 yılına kadar 11,2 milyara ulaşması bekleniyor (United Nation Raport, 2019). Artan nüfusun ihtiyaçlarını karşılamak için gıda üretimi de katlanarak artmaktadır. Bununla birlikte, sınırlı toprak ve su kaynakları, iklim değişikliği ve doğal afetlerdeki artış, sürdürülebilir tarım hedefine ulaşmak için önemli bir tehdit oluşturmaktadır. Bu zorluklar göz önüne alındığında, gıda güvenliği ülkemiz ve dünya için stratejik bir öneme sahiptir.

Yönetilebilir tarım faaliyetleri gıda güvenliğini sağlamanın temelini oluşturmaktadır. Tarım alanlarının belirlenmesi, ekili tarım ürünün tespiti; tarımsal ürünün konumu, sınırları, alanı, verimliliği ve miktarının hasattan önce hesaplanması tarım alanlarının yönetilebilmesi için en kritik faktörlerdir. Bu çalışmaların hızlı, zamanında ve düşük maliyetle yapılması önem arz etmektedir. Coğrafi bilgi sistemleri ve uzaktan algılama bu çalışmalara doğrudan katkı sağlayan baş faktördür.

Tarım arazileri her ne kadar sabit ve değişmeyen toprak parçaları olarak görülse de sınırları ve içeriği itibarıyla sanıldığından çok daha dinamik ve değişken bir yapıya sahiptir. Bu sebeple geniş çaplı tarım alanlarının yönetilmesi için güçlü sistemler gerekmektedir. Coğrafi bilgi sistemleri ve uzaktan algılama teknolojileri geniş alanları koordinatlı uydu veya insansız hava aracı fotoğrafları ile izleme, onlarca katmanlı verilerle aynı anda çalışma vb. kabiliyetleri ile tarım alanlarını izlemede vazgeçilmez bir teknolojidir.

Orta çözünürlüklü uydu görüntüleri; işlenmesinin kolay olması, ücretsiz temin edilebilmesi, bölgesel olmayıp tüm dünyayı kapsaması, zamansal frekansının yüksek olması, çoklu spektral bantlarıyla birçok alana çözüm bulması gibi faktörlerden dolayı tercih sebebi olmuştur. Bunun yanı sıra gelişen teknoloji ile daha yüksek mekânsal, zamansal ve spektral çözünürlüğe sahip uydu görüntüleri kolay ulaşılabilir ve uygun fiyata temin edilebilir hale gelmektedir.

Bu çalışmada uydu görüntüsü olarak iki farklı uydu grubundan elde edilen uydu görüntüleri temin edilmiştir. Birbirine üstün yönlerini görmek, tespit ve analiz etmek için hem ücretsiz temin edilebilen orta çözünürlüklü Sentinel-2 görüntüleri hem de nispeten daha üstün özelliklere sahip, ücretli Planet Scope görüntüleri kullanılmıştır.

Vektör veri olarak, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından yayınlanan idari sınırlar, Tapu Kadastro Genel Müdürlüğünden temin edilen parsel bilgileri, Tarım ve Hayvancılık Bakanlığı'ndan temin

edilen 2017, 2018, 2019 yıllarına ait çalışma alanını kapsayan TARBIİL verileri- bunlar tarım parsel sınırları, ürün bilgisi, ekim-hasat tarihleri vs.-, Avrupa Birlięi tarafından yayınlanan CORINE 2018 arazi verisi vb. kullanılmıřtır.

Verilerin toplanması, depolanması, sorgulanması, iřlenmesi, analiz edilmesi ve son ıktılarının alınması srecinde cretli, demo srm veya cretsiz olarak sunulan; ARCGIS 10.4, QGIS 3.18, Esa Snap, Erdas Image 2014, eCognition Developer, R Studio, Python, Weka, OTB Monteverdi programların yararlanılmıřtır.

alıřmanın fikrinin oluřmasında, uydu grnts seiminde, sınıflandırma metodu ve algoritmalarının belirlenmesinde, doęruluk analizleri vb. ařamalarında literatrde doęrudan yararlanılan bazı makaleler ve kitap blmleri ařaęıdaki gibidir;

(Yılmaz, 2018) Gediz Ovası, Manisa ilinde farklı tarımsal rnlerin rastgele orman algoritmasıyla nesne tabanlı sınıflandırılmasına ynelik bir alıřma yapmıřtır. Domates, biber, patlıcan, buęday, mısır, pamuk, zm, yonca ve zeytin gibi blgenin nde gelen tarım rnlerinin tespiti yapılmıřtır. Yalnızca NDVI bitki indeksinin kullanıldıęı uygulamadan arazi alıřmaları ve aynı blgedeki farklı bitkiler zerinde yapılan analizlerden faydalanılmıřtır.

(řallı, 2020)'ya gre Bursa, Karacabey ilesindeki domates rnlerini tespitine ynelik bir alıřma uzaktan algılama ve coęrafi bilgi sistemleri yardımı ok daha efektif yapılabilmektedir. Planet yksek znrlkl uydu grntsnden ok zamanlı veri seti oluřturulmuřtur. On farklı ana tarım rn tespiti iin piksel bazlı sınıflandırma yntemi kullanılmıřtır. NDVI bitki indeksi dıřında ASM (Angular Second Moment), Entropy ve MOC2(Information Measures of Correlation 2) doku parametreleri kullanılmıřtır. alıřmada kontroll sınıflandırma algoritmalarından olan Rastgele Orman algoritması tek sınıflandırma algoritması olarak kullanılmıřtır.

(Rao vd., 2021)'ye gre, Hindistan'da mısır, hardal, ttn ve buęday tarım alanlarının gzlemlenmesi ve tespit edilmesi Sentinel-1, Sentinel-2 ve Planet grntleri ile deęerli sonular ortaya koymaktadır. Her  grntnn hedef tespitlerin yapılmasında bařarılı bulunmasının yanı sıra kk tarım alanlarının tespitinde 3 m meknsal znrlkl Planet uydu grntlerinin kullanılmasının daha avantajlı olduęu vurgulanmıřtır.

(Mudereri vd., 2019)'ya gre Batı Kenya'da Mısır ekimi yapılan tarım alanlarındaki yabani otların coęrafi bilgi sistemleri ve uzaktan algılama yntemleriyle tespiti mmkndr. Planet Scope ve Sentinel-2 uydu grntlerinin kullanıldıęı

çalışmada sırası ile %92 ve %88 doğruluk oranı elde edilmiştir. Çok bantlı Sentinel-2 görüntüsünün tarım alanlarındaki başarısının yanı sıra Planet görüntülerinin daha doğru sonuç verdiği gözlemlenmiştir.

(Kobayashi vd., 2019)'ya göre Sentinel-2A görüntüsünün 13 bantlının tümü- yakın kızılötesi ve kısa dalga kızılötesi dalga boylarını içeren geniş bir spektral aralığı kapsar kullanılarak tarım arazilerinin sınıflandırılması manuel yöntemlere göre çok daha efektif yapılmaktadır. Çalışmada; Fasulye, Mısır, Buğday, Pancar, Çim alanlarının tespitinde Sentinel-2 görüntüsünün başarısı araştırılmıştır. Bantların yanı sıra 91 adet indeks üretilerek Rastgele Orman algoritması ile sınıflandırma işlemi gerçekleştirilmiştir. Bölge ve ürüne göre değişkenlik gösterse de indekslerin sınıflandırma başarısı çalışmaya fikir vermektedir.

(Vaiopoulos ve Karantzalos, 2016)'ın yaptığı çalışmada Sentinel-2 uydu görüntüsünün VNIR ve SWIR 20 m çözünürlüklü batlarının 21 farklı Pansharpening algoritması ile keskinleştirilmesi gerçekleştirilmiş ve kıyaslaması yapılmıştır. Algoritmaların başarıları hem manuel hem de otomatik görüntü kalitesi tahmin yöntemleri ile değerlendirilmiş fakat her iki yönteminde tahminleme için yeterli olmadığı ifade edilmiştir. Bunun yanı sıra MTF-GLP-CBD (Laplace piramidi bağlam temelli karar modeli), SFIM (Smoothing Filter-based Intensity Modulation / yumuşatma filtresi tabanlı yoğunluk modülasyonu) ve HPF (High-Pass Filtering / yüksek geçişli filtreleme) yöntemlerinin daha doğru sonuç verebileceği ve kullanım için daha uygun olacağı belirtilmiştir.

(Zhang vd., 2020)'ın yaptığı çalışma sınıflandırmada izlediği yol açısından çalışmaya benzerlik gösteren bir makaledir. Çin'de bir mahallenin tarım arazilerinde sekiz farklı ürünün parsel bazlı sınıflandırması yapılmıştır. Yazar ilgili kurumlarca üretilen parsel sınırlarının doğrudan çalışmada kullanılamayacağını manuel kontrollerle düzeltilmesi gerektiğini belirtmektedir. World View yüksek çözünürlüklü uydu görüntüsü yardımı ile vektör veriler düzeltilmiştir. Rastgele Orman ve Destek Vektör Makineleri algoritmaları ile yapılan sınıflandırma işleminde en yüksek doğruluk; %80,04 genel doğruluk ve 0,78 kappa değeri olarak sonuç alınmıştır.

(W. Li vd., 2019) çalışmada Sentinel-2 uydu görüntüsü bantları ile Planet Scope uydu görüntüsü bantlarının birbiri ile keskinleştirilmesinin doğru sonuç verip vermediği araştırılmıştır. Bu yönü ile teze önemli katkıda bulunmuştur. Temel yöntem 10 m çözünürlüklü Sentinel bantlarının 3m mekânsal çözünürlüklü Planet Scope görüntüsünün

tam dört katı olacak şekilde 12 m'ye yeniden örneklenmesi ardından Planet Scope görüntüsü ile keskinleştirilmesi gerçekleştirilmiştir. Pansharpening süreci ağırlık ve ayırma algoritmasını SupReME (çoklu spektral çoklu çözünürlük tahmini için süper çözünürlük) yaklaşımıyla gerçekleştirilmiştir. Çalışmada, Sentinel-2, Planet ve Füzyon görüntünün buğday bitkisinin Yaprak Alan İndeksi ayrı ayrı hesaplanmış ve füzyon görüntünün daha başarılı sonuç verdiği gözlemlenmiştir. Bu sonuç farklı uydu görüntülerinin bir arada kullanılmasının mümkün olduğu daha nihai doğruluğu artırması yönüyle uzaktan algılama çalışmalarına yön vermektedir.

(Rao vd., 2021), Doğu Hindistan'ın Bihar bölgesinde tarım arazilerinde yetiştirilen Mısır, Hardal, Tütün ve Buğday bitkilerinin Sentinel-1, Sentinel-2 ve Planet uydu görüntüleri ile sınıflandırılması yapılmıştır. Uydu görüntülerini ortak kullanabilmek için keskinleştirme (Pansharpening) işlemi yapılmamış olup yalnızca tüm görüntü ve bantlar 3 m'ye yeniden örneklenmiştir. Sınıflandırmada makine öğrenmesi kullanılmış olup Destek Vektör Makinaları (SVM) modeli uygulanmıştır. Planet görüntüsünün dahil edildiği sınıflandırma işlemlerinde genel olarak ve özellikle küçük tarım alanlarında Planet Scope'un sınıflandırma doğruluğunu artırdığı gözlemlenmiştir.

(Gašparović vd., 2018) yaptığı çalışmada Hırvatistan'ın başkenti Zagreb'te 641 km²'lik kentsel alanda bitki örtüsünün tespiti ve izlenmesini hedeflemiştir. Bu çalışmada Sentinel-2 (10 m, 20 m) ve Planet (3,7 m) farklı çözünürlüklü uydu görüntülerinin keskinleştirme(pansharpening) işlemi ile bir arada kullanılmasının sınıflandırmaya katkısı araştırılmıştır. Görüntü füzyonunda P+XS yöntemi kullanıştır. Sentinel-2 10 m çözünürlüklü bantları (2,3,4,8), sırasıyla Planet Scope (1,2,3,4) bantları ile füzyon edilmiş; Sentinel-2 20 m çözünürlüklü 5,6,7 bantları Planet 3 ve 4'nolu bantlarının ortalaması ile füzyon edilmiştir. Sınıflandırma işleminde ise Rastgele Orman makine öğrenme algoritması kullanılmıştır. Füzyon işleminin yalnız Sentinel-2 görüntüsünden daha doğru sonuç verdiği fakat planet görüntüsü ile yakın sonuçlar verdiği tespit edilmiştir.

(Kaplan, 2020) yer görüntüleme, iklim değişikliği, güvenlik, acil durum yönetimi gibi birçok konuda katkı sağlayan Sentinel-2 uydu görüntüsünün daha yüksek çözünürlüklü Planet (3 m) uydu görüntüsü ile keskinleştirilmesindeki başarısını araştırmıştır. Bu kapsamda; BDSD (Band-dependent spatial detail), ATWT (a trous wavelet transformation) ve MTF-GLP-CBD (Laplace piramidi bağlam temelli karar modeli) olmak üzere üç farklı pansharpening (keskinleştirme) yöntemi karşılaştırılmıştır.

Doğruluk analizi için bias, CC (correlation coefficient / korelasyon katsayısı), UIQI (the universal image quality index / evrensel görüntü kalitesi indeksi) ve ERGAS olmak üzere dört analiz yöntemi kullanılmıştır. Sentez verilerin iyi ve güçlü sonuçlar ürettiği tespit edilmiş olup özellikle pankromatik bantın olmadığı durumlarda farklı uydu görüntülerinin füzyon edilmesinin mümkün olduğu ortaya konulmuştur.

(Şerifoğlu vd., 2021) genel olarak kullanım amaçları, girdi ve çıktı veri setleri vb. yönleri ile pansharpening yöntemlerini karşılaştırmalı bilgileri detaylarıyla incelemiştir. Keskinleştirme işlemi sonrası çıktı görüntünün doğruluk tespiti için kullanılan yöntemlerinde detayları incelemiştir. Tez uygulamasındaki keskinleştirme yöntemlerinin belirlenmesine fikir vermiştir.

(Kpienbaareh vd., 2021) çalışmasında; ürün tipi ve arazi örtüsü haritalamasındaki doğruluğun artırılması için Sentinel-1, Sentinel-2 ve Planet Scope uydu görüntülerinin farklı kombinasyon ve yöntemlerle füzyon görüntülerinin kullanmıştır. Görüntü füzyonunda P+XS yöntemi kullanmıştır. Sentinel-2 10 m çözünürlüklü bantları (2, 3, 4, 8), sırasıyla Planet Scope (1, 2, 3, 4) bantları ile füzyon edilmiş; Sentinel-2 20 m çözünürlüklü 5, 6, 7 bantları Planet Scope 3 ve 4' nolu bantlarının ortalaması ile füzyon edilmiştir. Sınıflandırma işleminde Random Forest makine öğrenme algoritması kullanılmıştır. Sentinel-2 + Planet Scope füzyon görüntüsünün doğruluğu artırdığı gözlemlenmiştir.

(Z. Li vd., 2020)'ye göre sentinel-2 uydu görüntüsünün 10 m ve 20 m'lik bantlarını Planet Scope 3 m mekânsal çözünürlüklü bantları ile keskinleştirilebilmektedir. Çalışmada, öncelikle Sentinel -2 görüntüleri 3.33 m piksel boyutlarına "bilinear" yeniden örneklenmiştir. Daha sonra her Sentinel bant ayrı ayrı HPF ve M3 sharpening algoritmaları kullanılarak keskinleştirilmiştir. Kullanılan HPF ve M3 algoritmalarından HPF'nin daha başarılı olduğu tespit edilmiştir.

(Aguilera, 2020) farklı makine öğrenme algoritmalarının (SVM, RF, ANN, KNN, DT) sınıflandırmadaki başarısını incelemiştir. Çalışmada yüksek spektral çözünürlüklü Sentinel-2 ve yüksek mekânsal çözünürlüklü Planet Scope 'un füzyon görüntüsü kullanılmıştır. Füzyon işleminde P+XS Değişken Metodunu kullanmıştır. Sentinel-2 ve Planet kırmızı, yeşil, mavi ve yakın kızılötesi bantlarını sırasıyla füzyon etmiş Sentinel-2 5, 6, 7, 8A, 11, 12 bantlarını Planet 3 ve 4 bantlarının ortalamasıyla füzyon etmiştir. Sınıflandırma işlemi; füzyon edilmiş bantlar, normalize edilmiş fark bitki örtüsü indeksi (NDVI), normalleştirilmiş fark nem indeksi (NDMI), normalize edilmiş yerleşim alanı

indeksi (NDBI) ve Modifiye Toprak Bitki İndeksi (MSAVI) indeksleri kullanılarak 5 farklı algoritmayla gerçekleştirilmiştir. Destek Vektör Makinaları daha başarılı bulunmuştur.

(Dizdaroğlu, 2019) Manisa ili Gediz Havzasında belirlenen çalışma alanında Sentinel-1 ve Sentinel-2 uydu verileri kullanılarak tarımsal ürünlerinin farklı makine öğrenme algoritmaları ile sınıflandırmıştır. Sınıflandırma doğruluğunu azaltacağı düşüncesiyle Sentinel-2 görüntüsünün yalnızca 2 (B), 3 (G), 4 (R) ve 8 (NIR) bantları kullanılmıştır. Sınıflandırma algoritması olarak Karar Ağacı, Rastgele Orman ve Destek Vektör Makineleri algoritmaları kullanılmıştır. Yapılan obje tabanlı sınıflandırma işlemlerinin neticesinde Sentinel-1 (VH, VV), Sentinel-2 (B, G, R, NIR) ve NDVI indeksi kombinasyonu ile yapılan sınıflandırma işlemi daha başarılı bulunmuştur.

1.1. Tezin Amacı

Çalışmanın en temel amacı gıda güvenliğinin sağlanması için tarımsal alanların izlenmesinde uzaktan algılama ve coğrafi bilgi teknolojilerinin katkısının araştırmaktır. Bu kapsamda, manuel yöntemlerle yönetilmesi mümkün olmayan tarım alanlarındaki ürünlerin tespitinde farklı özelliklere sahip uydu görüntülerinin ve farklı makine öğrenme algoritmalarının nasıl katkıda bulunacağı araştırılmıştır.


1.2. Tezin Kapsamı

Araştırmanın yapımına elverişli; alan, uygun zaman ve yeterli verilerin seçilmesi ve karşılaşılan kısıtlar mümkün olduğunca aşılacak çalışma yeterliliğinin oluşturulma süreci hakkında bilgi verilmiştir.

1.2.1. Mekânsal kapsam


Bu tez kapsamında yapılan çalışma alanı Gediz Havzası içerisinde bir tarım bölgesi seçilmiştir. Gediz Nehri'nin uzandığı havza, verimli ova topraklarına ve tarıma elverişli bir iklime sahip olduğundan Türkiye'deki toplam tarımsal üretimin %10'u bu havzadan karşılanmaktadır. Havzanın, %50'si (8.559.829 ha) tarımsal alan, %47'si (7.980.508 ha) orman ve yarı doğal alan, %2'si (316.015 ha) ise şehir vb. insan eli ile değiştirilmiş bölgeleri içeren yapay alandır (<http-1>).

Çalışma alanı, Manisa ili merkezinin kuzey-doğusunda ve geneli Saruhan ilçesi içinde kalan yaklaşık 150 bin dekarlık bir alanı kapsamaktadır (Görsel 1.1). Ülkemizin en verimli tarım arazilerinden birisi olması sebebiyle yılda 2-3 hasat alanın bölgede Zeytin, Üzüm, Buğday, Mısır, Domates, Pamuk, Kiraz, Erik, Arpa, Tritikale, Fiğ, Biber, Tütün, Şeftali, Yonca, Ceviz vb. 90'dan fazla çeşit tarım ürünü yetiştirilmektedir.




Görsel 1.1. Ülke ve Manisa ili ölçeğinde çalışma alanı haritası

Havza Kütahya, Uşak, İzmir, Denizli, Aydın, Balıkesir illerinin yanı sıra yüz ölçüm itibarı ile büyük ölçüde Manisa ilini içine almaktadır. Gediz Havzasının kapsadığı iller Görsel 1.2’de, yüz ölçüm oranları ise Şekil 1.1’de verilmiştir.



Görsel 1.2. Gediz Havza sınırları ve kapladığı iller



Gediz Havzasındaki İller

Şekil 1.1. Gediz Havzasını oluşturan illerin havza içerisine giren alanları (%)

1.2.2. Zamansal kapsam

2020 yılında başlayan çalışmaya için ilgili kurumlardan çalışma alanını kapsayan 2019 yılına ait veri seti temin edilmiştir. Çalışma kapsamında yaz döneminde yetişen bitkilere odaklanılmıştır. Yaz döneminde yetişen bitkiler için ortak bir zaman belirlemek amacıyla tarımsal ürünleri temsil eden parsellerin ortalama NDVI değerleri Sentinel-2 görüntülerinden üretilerek analiz edilmiştir.

1.2.3. Veri kapsamı

Çalışma alanının sınırlarında yer alan yaklaşık 50 bin parselde 90'dan fazla çeşit Yaz ve Kış ürünü yetiştirilmektedir. Fakat bu parsellerin %80'inde yaz döneminde Domates, Pamuk, Mısır, Üzüm ve Zeytin yetiştiriciliği yapılmaktadır. İlgili kurumlardan elde edilen tarım parselleri dikkate alınarak çalışmada bu beş ürün üzerine yoğunlaşmıştır. Tarım parsellerinin yanında, analiz işlemlerinde Sentinel-2 ve PlanetScope görüntülerinden faydalanılmıştır.

1.3. Hipotez

Bu çalışmada spektral, mekânsal ve zamansal çözünürlükleri farklı iki uydu görüntüsünün ayrı ayrı ve füzyon edilerek, farklı bant ve indekslerle, güncel ve birbirinden farklı makine öğrenme algoritmaları kullanılarak tarım alanlarını sınıflandırmadaki başarısı araştırılmaktadır. Parsel bazlı yapılan çalışmaların verimliliği de ortaya konulmaktadır. Tezin hipotezi;

- Gıda güvenliğini sağlamak için yapılan tarım alanlarının sınıflandırılmasında, farklı uydu görüntüleri füzyon edilerek ve parsel bazlı tespitlerle daha yüksek doğruluklu sonuçlar elde edilir.

Literatürde benzer çalışmaların bulunması rağmen, farklı uydu görüntülerinin füzyon edilerek üstün yönlerinin avantaja çevrilmesi, tamamen parsel bazlı sınıflandırma işleminin yapılması ve güncel makine öğrenme algoritmalarının tarım alanlarının tespitinde kullanılması tezin özgünlüğüdür.

1.4. Araştırma Soruları

Tez çalışması kapsamında cevap aranacak sorular aşağıdaki şekilde özetlenmiştir.

“Tarım alanlarının uzaktan algılama ve coğrafi bilgi sistemleri ile izlenmesi gıda güvenliğinin sağlanmasına katkı sunar mı?”, “Farklı bant sayısına, farklı spektral ve mekânsal çözünürlüklere sahip uydu görüntülerinin tarım ürünlerini tespit etmede üstün yönleri var mı?”, “Parsel bazlı (Nesne tabanlı) ürün tespit çalışmaları yapılabilir mi?”, “Farklı makine öğrenme algoritmalarının tarım alanlarının parsel bazlı tespitinde tahmin ve tespit başarısı nedir?”, “Füzyon görüntünün tarım alanlarının tespitinde kullanılması başarıyı artırır mı?” soruları çalışma içerisinde araştırılmıştır.

1.5. Tezin Sınırlılıkları

Kadastro parsellerinin tarımsal üretim yapılan alanlarla uyuşmaması, çalışma içerisinde tarım parsellerinin birçoğunun manuel olarak yeniden çizilmesine ve zaman kaybına sebep olmuştur.

İlgili kurumlarca çiftçilerin beyanları veya arazi çalışmalarıyla toplanan bazı veriler kişisel verilerin korunması amacıyla üçüncü kişilerle paylaşılmamaktadır. Bu da çalışmada bazı verilerin manuel üretilmesine ve zaman kaybına sebep olmuştur.

Kamu kurumlarının veya özel sektörün çalışmaya ilgin olumsuz tecrübelerinin paylaşılmaktan imtina edilmesi çalışma içerisinde karşılaşılan her sorunun yeniden tecrübe ederek öğrenilmesine yol açmaktadır.

İlgili kurumlardan edinilen verilerin çalışmaya başlama tarihinden önce (2019 yılına ait) olmasından dolayı arazi çalışması yapılamamıştır.

Çalışmaya altlık oluşturan raster verilerin ücretsiz olarak sınırlı sayıda veya alanda temin edilmesi yapılabilecek maksimum çalışma alanını sınırlamıştır.

2. KURAMSAL TEMELLER

Çalışmadaki bilimsel kabuller, farklı disiplinlerin ilişkileri, kullanılan teknolojiler, metotlar, yöntemler, formüller; uygulama kısmında ayrıca değinilmesi mümkün olmayan yalnızca atıfta bulunulan detaylar, araştırmada geçen temel kavramlara ilişkin kuramsal çerçeve bu bölümde başlıklar halinde aktarılmıştır.

2.1. Gıda Güvenliği, Uzaktan Algılama ve CBS İlişkisi

Gıda güvenliği, uzaktan algılama (UA) ve coğrafi bilgi sistemleri (CBS) arasındaki ilişki oldukça önemlidir. Bu alanlar birbirini tamamlayan ve gıda güvenliği ile tarım yönetimi konularında önemli katkılarda bulunabilen disiplinlerdir.

Uzaktan algılama, yeryüzünden uzaktaki nesnelerin, alanların veya olayların bilgisini elde etmek için uzaktan algılama teknolojilerini kullanma sürecidir. Bu teknoloji, uydu görüntüleri, hava fotoğrafları ve diğer uzaktan algılama araçları ile yüzeydeki değişiklikleri izleme yeteneği sunar. Tarım alanında, bitki örtüsü durumu, su kullanımı, hastalık tespiti, hasat tahminleri gibi bir dizi faktörü izlemek ve analiz etmek için yaygın olarak kullanılır.

CBS, coğrafi verileri toplamak, depolamak, analiz etmek ve sunmak için kullanılan bir teknoloji ve yazılım sistemidir. CBS, mekânsal verileri haritalar ve grafikler aracılığıyla görselleştirme yeteneği sunar. Gıda güvenliği ile ilgili olarak, CBS, coğrafi verilerin yönetimi ve analizi ile gıda üretimi, tedarik zinciri izleme, hastalık izleme ve kriz yönetimi gibi konularda önemli bir rol oynar.

Gıda güvenliği, gıda üretim alanlarının belirlenmesi, doğru ürünün ekilmesi, işlenmesi, depolanması, dağıtımı ve tüketilmesi sürecinin tamamında sağlanması gerekmektedir. Bu süreçte gıdaların insan sağlığına zarar vermemesi ve tüketicinin güvende olmasının yanı sıra yeteri kadar sağlıklı gıdanın sürdürülebilir şekilde üretilmesi önem arz etmektedir. Gıda güvenliği ile ilgili veriler, coğrafi konumla sıkı bir ilişki içerir. Bölge veya ülke ölçeklerinde öngörülebilir, sürdürülebilir gıda yönetimi için tarım alanlarının uzaktan algılama ve coğrafi bilgi sistemleri teknolojilerinden yararlanılması kaçınılmazdır.

Bu ilişkide, uzaktan algılama tarım alanlarının ve bitki örtüsünün durumunu izlemek için kullanılabilir. CBS, bu verileri haritalar üzerinde görselleştirip, karar vericilere ve çiftçilere veri tabanlı kararlar almalarında yardımcı olmaktadır. Bu, daha

etkili ve sürdürülebilir tarım uygulamalarını teşvik etmektedir. CBS ve uzaktan algılama, su kaynakları, toprak kalitesi ve bitki örtüsü gibi önemli gıda üretim kaynaklarının izleyerek verimliliği artırmak ve gıda güvenliğini sağlamak için önemlidir.

Gıda güvenliği, uzaktan algılama ve CBS'nin birleştirilmesi, daha iyi tarım uygulamalarını teşvik etmek, gıda kaynaklarını etkili bir şekilde yönetmek ve tüketici güvenliğini artırmak için büyük bir potansiyele sahiptir. Bu disiplinlerin birlikte kullanılması, gıda güvenliğinin artırılmasına ve gıda kaynaklarının daha etkili bir şekilde yönetilmesine önemli rol almaktadır.

2.2. Tarım Alanlarının Uzaktan Algılama Yöntemleri ile İzlenmesi

Tarım alanlarının uzaktan algılama yöntemleri ile izlenmesi, modern tarım yönetimi ve gıda üretiminin verimliliğini artırmak, su kaynaklarını korumak ve çevresel sürdürülebilirliği sağlamak için önemli bir araçtır. İşte tarım alanlarının uzaktan algılama yöntemleri ile izlenmesi için kullanılan başlıca teknikler:

Uydu Görüntüleri: Uydu görüntüleri, dünya yüzeyinin farklı bölgelerini yüksek çözünürlüklü olarak görüntülemek için kullanılır. Uydu görüntüleri, bitki örtüsü, toprak kalitesi, su kullanımı ve hasat dönemleri gibi tarım alanlarına ilişkin önemli bilgileri sağlar. Bu görüntüler, tarım alanlarının büyüklüğünü, verimliliği ve değişikliklerini izlemek için kullanılır.

Havadan Görüntüleme: Havadan görüntüleme, insansız hava araçları (İHA) veya insansız hava araçları (UAV) gibi cihazlar aracılığıyla tarım alanlarının yüksek çözünürlüklü görüntülerini toplama yöntemidir. Bu yöntem, bitki sağlığı, hastalık tespiti, sulama ihtiyacı ve hasat tahminleri gibi verilere erişim sağlar.

Spektral Görüntüleme: Spektral görüntüleme, bitkilerin fotosentetik aktivitelerini izlemek için kullanılır. Bitkiler, farklı dalga boylarında farklı şekillerde yansır ve emerler. Bu nedenle, spektral görüntüleme cihazları, bitki sağlığı, besin maddesi eksiklikleri ve hastalık tespiti için kullanılır.

GPS Teknolojisi: Küresel Konumlandırma Sistemi (GPS) tarım makinelerinin ve traktörlerin tarlalarda daha hassas bir şekilde gezinmelerine yardımcı olur. Bu, verimliliği artırırken yakıt ve kaynak tasarrufu sağlar.

Sıcaklık İzleme: Kızılötesi (Infrared-IR) kameralar, bitkilerin sıcaklık değişikliklerini izlemek için kullanılır. Bu, bitki stresi, su eksikliği ve hastalık tespiti gibi önemli bilgilere yol açabilir.

Zaman Serisi Analizi: Uzaktan algılama verileri, zaman içinde tarım alanlarının değişimini izlemek için kullanılır. Hasat dönemleri, bitki büyümesi ve verimliliği izlemek için zaman serisi analizi yapılabilir.


İklim Verileri: İklim verileri, hava durumu, sıcaklık, yağış ve rüzgâr gibi faktörleri izleyerek tarım alanlarının yönetimine yardımcı olur. Bu veriler, sulama planlarını ve ekim dönemlerini optimize etmeye yardımcı olabilir.

Tarım alanlarının uzaktan algılama yöntemleri ile izlenmesi, veri analizi, coğrafi bilgi sistemleri (CBS) ve makine öğrenme teknikleri ile birleştirildiğinde, tarım yönetimi daha hassas hale gelir ve gıda üretimi artırılabilir. Bu teknolojiler aynı zamanda su kaynaklarının korunması, çevresel sürdürülebilirlik ve tarım yönetiminde verimlilik artışı gibi önemli hedeflere ulaşmak için kullanılır.

2.3. Uzaktan Algılamanın Temelleri

Elektromanyetik ışınım/enerji, eşit bir şekilde hareket eden harmonik dalgaların, ışık hızıyla periyodik olarak hareket eden tüm enerji türlerini ifade eder. Harmonik dalgalar ise, düzenli aralıklarla hareket eden dalgaları temsil eder. Elektromanyetik enerjinin sadece bir türü görünür ışıktır; diğerleri mor ötesi, radyo dalgaları, X-ışınları, ısı vb. farklı dalgalardır (Şekil 2.1).

Elektromanyetik dalgalar, birbirine dik Manyetik (M) ve Enerji (E) alanlarından oluşur ve hepsi ışık hızında ($c = 3 \times 10^8 \text{ m/s}$) hareket eder. Parçacık ve dalga modeli Şekil 2.1'de açıklanmaktadır.



Şekil 2.1. Elektromanyetik salınım


Elektromanyetik ışınlam, katı, sıvı, gaz gibi maddenin herhangi bir haline temas ettiğinde, yön, yoğunluk, polarizasyon, faz ve dalga boyu gibi birçok faktör açısından çeşitli değişikliklere uğrar. Uzaktan algılama çalışmalarında, bu değişiklikler tespit edilir ve kaydedilir. Bu işlemlerin sonucunda elde edilen görüntüler ve diğer veriler, her nesnenin özelliklerini belirlemek amacıyla uzaktan algılama çalışmaları bağlamında yorumlanır (Ömerci C., 1987).

Aslında, uzaktan algılamanın temeli, nesneler ile enerji arasındaki bu ilişkilere dayanır. Ayrıca enerjinin dalga boyu, cismin sıcaklığı ve bunlarla ilişkili olarak yayılan enerji miktarı da uzaktan algılamada önem taşımaktadır (Özkan, 1988)

Elektromanyetik spektrum, gama ışınlarından radyo dalgalarına kadar tüm elektromanyetik dalgaları içeren bir sıralamadır (Şekil 2.2). Başka bir deyişle, bu spektrum, dalga boylarının nanometrelerden kilometrelere kadar uzandığı sürekli bir enerji aralığını ifade eder. Dalga boyu ve enerji arasındaki ilişki, E enerjisi için b Planck sabiti, c ışık hızı ve λ dalga boyunu içeren eşitlik Şekil 2.2’de gösterilmiştir. Bu eşitlik, enerjinin dalga boyuyla ters orantılı olduğunu göstermektedir.

$$E = \frac{b*c}{\lambda} \quad (2.1)$$

Bütün cisimler, üzerlerine düşen elektromanyetik enerjinin bir kısmını geri yansıtırlar. İnsan gözü bu yansıyan enerjiyi algılar. İnsan gözü, elektromanyetik tayfin görünür ışık bölgesine duyarlıdır. İnsan gözünün en hassas olduğu dalga boyu 550 nm'dir. Görünür ışık, elektromanyetik tayfin en uzun radyo dalgalarından en kısa dalga boylu gama ışınlarına kadar uzanan küçük bir bölümünü içerir (Şekil 2.2).



Şekil 2.2. Elektromanyetik Spektrum

Elektromanyetik spektrum, kolaylıkla kullanılabilmesi için özel kesimlere bölünmüş olsa da kesin bir sınıra sahip değildir. Farklı ışınım aralıklarını tanımlamak için uzaktan algılamanın değişik teknikleri kullanılmıştır. Görünür ışıma, elektromanyetik spektrumun 0,4-0,7 μm aralığındaki son derece küçük bir bölümünde yer alır. Elektromanyetik spektrumun çeşitli aralıklarında yapılan algılamalarla yeryüzü hakkında çok çeşitli özellikler tespit edilip yorumlanabilir. Uzaktan algılamada en yaygın kullanılan dalga boyları, görünür (0,4–0,7 μm), kızılötesi (0,7–14 μm) ve mikrodalga (1–100 mm) ışınlarıdır (Şekil 2.2). Elektromanyetik spektrumun kızılötesi ve görünür bölgelerinde enerjileri algılamak için multispektral optik sensörler tercih edilirken, uzun dalga boylarında aktif veya pasif mikrodalga sensörleri kullanılır.

Uzaktan algılama sistemleri, elektromanyetik ışınının kullanıldığı temel dört bileşenden meydana gelir. Elektromanyetik dalganın spektrum içindeki konumu, frekansı ya da dalga boyu ile tanımlanır. Frekans (ν), bir saniye içinde herhangi bir noktadan geçen dalga sayısını ifade ederken, dalga boyu (λ) ise iki dalga zirvesi ya da çukuru arasındaki uzaklığı temsil eder. Bu nedenle dalga boyu ile frekans arasında ters orantılı bir ilişki bulunmaktadır.

$$\nu\lambda = c \quad (2.2)$$

Bu formülde c ışık hızıdır. Elektromanyetik dalganın enerji formülü ise bu şekildedir;

$$E = h\nu = h\frac{c}{\lambda} \quad (2.3)$$

Tablo 2.1. Elektromanyetik dalga tiplerinin kullanım ve etkileri

Elektromanyetik dalga	Üretim Şekli	Uygulama Amacı	Kullanım ve Etkileri
Gama ışını	Nükleer bozunum	Nükleer Tıp	Medikal Çalışmalar. Kanserle neden olabilir.
X-ışını	İvmelenen yükler	Medikal ve Güvenlik	Medikal Çalışmalar. Kanserle neden olabilir.
Morötesi (UV)	Termal radyasyon ve elektron geçişleri	Sterilizasyon	Vitamin Üretimi. Kanserle neden olabilir.
Görünür ışık	Termal radyasyon ve elektron geçişleri	Pek çok alan	Fotosentez ve görme olayında kullanılır.
Kızılötesi (IR)	Termal radyasyon ve elektron geçişleri	Termal görüntüleme	Sera etkisine sebebiyet verir.
Mikrodalga	İvmelenen yükler ve termal radyasyon	İletişim, fırınlar ve radar	Mikrodalga cihazlar.
Radyo Dalgaları	İvmelenen yükler	İletişim ve uzaktan kumanda	Manyetik Rezonans (MR) görüntülemede kullanılır.


2.4. Elektromanyetik Enerjiye Atmosferik Etkiler

Aktif veya Pasif tüm ışınlamalar kaynağından çıkıp algılayıcı a ulaşır ışınlamayı tamamlayana kadar ki katetti yolda atmosferden geçmektedir. Elektromanyetik enerji atmosferden geçerken atmosferik gazlar, su molekülleri vb. etkileyicilere maruz kalmaktadır. Bu etki izleyicilerle temas ettiğinde yansıma, emilim veya dağılma yaşayabilir.

Dağılma: Atmosfer, elektromanyetik ışınlamının seyahati sırasında bu ışınlamının yönünü değiştiren dağılmalara neden olabilir. Farklı dalga boylarındaki ışınlam, farklı derecelerde dağılma yaşar. Bu dağılma, algılanan sinyallerin netliğini etkileyebilir.

Emilim: Atmosferdeki gazlar, bazı dalga boylarındaki elektromanyetik ışınlamı absorbe edebilir. Bu absorpsiyon, bazı frekans aralıklarının uzaktan algılama için uygun olmadığı anlamına gelir. Özellikle su buharı ve karbondioksit, belirli dalga boylarını emebilir.

Yansırma: Atmosfer, elektromanyetik ışıının bir kısmını yansıtabilir. Bu yansırma, yeryüzünden gelen sinyallerin algılanmasını ve yorumlanmasını karmaşıklıştırabilir.




Şekil 2.4. Cisimlerin spektral yansıması

Her madde, yansıma özellikleri açısından farklı karakteristiklere sahiptir. Bu özellikler, spektral yansıma eğrisi olarak adlandırılan bir grafikte gösterilir. Bu eğri, ışığın dalga boyu ile ilişkilendirilerek, yüzeyden yansıyan ve yüzeye gelen toplam ışının yüzdesini gösterir. Maddelerin spektral yansıma katsayıları ölçülerek spektral yansıma eğrileri oluşturulur. Bu eğriler, uygun algılayıcının ve uzaktan algılama çalışmasının yapılacağı bölgenin seçiminde önemli bir rol oynar. Bu nedenle, maddelerin spektral yansıma özelliklerinin bilinmesi, gereken spektral bantların seçiminde kritik bir faktördür. Spektrometre cihazları, çeşitli yüzeylerin özgün spektral imzalarını oluşturabilir. Bu sayede, herhangi bir spektral bantta bir nesnenin yüzeyinden yansıyan elektromanyetik radyasyon algılanabilir. Bu işlem, her bant için tekrarlanarak, farklı dalga boylarında spektral imzalar elde edilir. Her malzemenin, güneş ışığının belirli bir dalga boyunda yüzeyi nasıl etkilediğine bağlı olarak farklı tepki değerleri vardır (Şekil 2.4). Bu temel özellik, farklı malzemeleri ayırt etmeye yardımcı olur. Belirli bir arazi örtüsünün spektral imzası, tepki özelliklerinin dalga boyu ile ilişkilendirilmesiyle tanımlanır. Her malzeme kendi benzersiz spektral yansımasına sahip olmasına rağmen, en yaygın olanları toprak, su ve yeşil bitki örtüsüdür (http-3).


2.4.1. Bitkilerin spektral yansımaları

Genel olarak, sağlıklı bitki örtüsü, görünür bölgede çok iyi bir elektromanyetik enerji emicidir. Görsel 2.1'teki grafikte görüldüğü gibi, Klorofil, mavi ($0.45 \mu\text{m}$) ve kırmızı ($0.67 \mu\text{m}$) dalga boylarında ışığı güçlü bir şekilde emer ve yeşil ışıktaki güçlü bir şekilde yansıtır. Bu nedenle sağlıklı bitki örtüsü gözle yeşil olarak algılanır. Sağlıklı bitkiler, yakın kızılötesinde $0,7$ ila $1,3 \mu\text{m}$ arasında yüksek bir yansıtma oranına sahiptir (Şekil 2.5).




Görsel 2.1. Sağlıklı bitkilerdeki yansımalar

Bu öncelikle bitki yapraklarının sağlıklı içyapısından kaynaklanmaktadır. Bu içyapı farklı bitki türleri arasında değişiklik gösterdiğinden, yakın kızılötesi dalga boyları farklı bitki türlerini ayırt etmek için kullanılabilir.



Şekil 2.5. Bitkilerin spektral yansıması

Yaprakların yapısı, 0,75-1,4 μm dalga boyları arasındaki Yakın kızılötesi (NIR, Near-Infrared) ışınlarla hassas bir şekilde tespit edebilir. Yapraklara yönlendirilen enerjinin büyük bir kısmı, yaprak yüzeyinden yansırken, geriye kalan kısmı büyük ölçüde geçer ve sadece çok küçük bir kısmı emilir(http-4).



Şekil 2.6. Klorofil spektral yansıması

Bitkilerin toplam nem içeriğini kontrol etmek için orta kızılötesi yansıma esas alınır, bu sayede gelen radyasyonun büyük bir kısmı bitki tarafından su içeriği tarafından emilir ve geriye kalanı yansıtılır.

Ayrıca, bitkilerdeki hücre yapısını etkileyen hastalıkları tespit etmek için 0,98-1,20 µm dalga boyları arasında çalışan sensörler kullanılabilir. Başka bir deyişle, bitkilerin spektral yansıması; yakın kızılötesi bölgede hücre yapısına, orta kızılötesi bölgede nem içeriğine ve görünür bölgede klorofil pigmentlerinin yansıma ve emilimine bağlıdır (Şekil 2.6).

Bitkilerin yansımasını etkileyen pek çok faktör bulunmaktadır. Bu faktörler bitkilerin içsel özelliklerinden kaynaklanabileceği gibi dış etkenlere de bağlı olabilir. Bitkilerin yaprak yapısı, büyüme dönemi, morfolojik yapısı, yaprağın yaşı, su kaybı, tuzluluk düzeyi, mineral eksiklikleri, hastalıklar ve zararlılar gibi etkenler yansıma üzerinde etkili olabilir (Karadağ, 2016).

Sağlıklı ve canlı bitkilerin spektral yansıma eğrileri genellikle bir dizi zirve ve çukurdan meydana gelir. Bu spektral grafikte görülen çukurlar, bitki yapraklarında bulunan pigmentler tarafından oluşturulur. Şekil 2.6'daki gibi Klorofil a ve klorofil b gibi maddeler, belirli dalga boylarındaki enerjiyi yaklaşık olarak 0,45 ve 0,67 µm'ye kadar absorbe eder (Senanda, 1986). Bu, bitki yapraklarının mavi ve kırmızı enerjiyi emdiği ve yeşil enerjiyi insan gözü için görünür hale getirdiği bir etki yaratır. Ancak, bitkiler beklenen büyümeyi veya verimi engelleyen streslere maruz kalırlarsa, klorofil üretimi azalabilir veya tamamen kaybolabilir. Bu tür durumlarda, mavi ve kırmızı bantlardaki klorofil absorpsiyonunun azalması, sağlıklı yeşil bitkilerin renginde değişikliklere yol açabilir (Ş. Kavak, 1998).

2.4.1.1. Tarım bitkilerinin spektral yansıması

Tarım bitkilerinin spektral yansıması, bitkilerin ışığın farklı dalga boylarıyla etkileşime girme ve yansıtma şeklini ifade eder. Bu etkileşim, uzaktan algılama, bitki sağlığı değerlendirmesi ve hassas tarım dahil olmak üzere çeşitli amaçlar için önemlidir. Farklı bitki türleri, sağlık koşulları ve hatta belirli bitki bileşenleri (yapraklar, gövdeler, meyveler) benzersiz spektral yansıma modelleri sergiler.

Bitkilerin spektral yansımaları veya spektral tepkileri hakkında bilgi toplamak için yersel çalışmalar dışında genellikle uydu veya drone tabanlı sensörler gibi uzaktan algılama teknikleri kullanılarak ölçülür. Farklı tarım bitkileri, pigmentlerindeki, yaprak

yapılarındaki ve biyokimyasal bileşimlerdeki farklılıklar nedeniyle benzersiz spektral imzalar sergiler. Bu spektral imzalar, bitkilerin ışığı elektromanyetik spektrumun farklı dalga boylarında yansıtma biçimleriyle karakterize edilir.

Özetle, tarımsal bitkilerin spektral yansıması, mahsulleri izlemek ve yönetmek için değerli bir araçtır. Araştırmacılar ve çiftçiler, bitkilerin farklı dalga boylarında ışıkla nasıl etkileşime girdiğini inceleyerek bitki sağlığı, stres seviyeleri ve büyüme hakkında bilgi edinerek daha bilinçli karar verebilir ve sürdürülebilir tarım uygulamaları sağlanabilir.

2.4.2. Toprağın spektral yansıması

Toprağın spektral yansıması, toprağın farklı dalga boylarındaki ışıkla nasıl etkileşime girdiğini ve elektromanyetik spektrumun belirli kısımlarını nasıl yansıttığını ifade eder. Bu etkileşim, toprağın bileşimi, mineral içeriği, nem seviyeleri ve diğer özellikleri hakkında değerli bilgiler sağlayabilir.

Toprak, ışığı farklı dalga boyu aralıklarında çeşitli şekillerde yansıtır, emer ve iletir. Topraktaki mineraller, organik madde ve nem gibi farklı bileşenlerin farklı spektral imzaları vardır. Toprağın spektral yansıması bitkilere göre daha az değişkendir. Şekil 2.5'e bakıldığında da en az tepe çukur toprak sınıfında görülmektedir.

2.5. Uzaktan Algılama Sistemleri

Uzaktan algılama sistemleri, uydular, uçaklar, dronlar veya diğer platformlardaki sensörleri kullanarak, Dünya'nın yüzeyi ve atmosferi hakkında belirli bir mesafeden bilgi toplamak için kullanılan teknolojilere ve yöntemlere atıfta bulunur. Bu sistemler, elektromanyetik spektrumun çeşitli dalga boylarındaki verileri yakalar ve çevresel izleme, kaynak yönetimi, afet değerlendirmesi, tarım, şehir planlaması ve daha pek çok alandaki uygulamalar için değerli bilgiler sağlar.

Modern uzaktan algılamanın en eski uygulamaları, teknolojiye gelişmeler ve hava fotoğrafçılığı ve erken uydu sistemlerinin kullanımı ile 20. yüzyılın ortalarına kadar izlenebilir.

Uçağa monte edilmiş kameraların 19.yy. sonlarında hava fotoğrafçılığı amaçlı kullanılması ile başlayan uzaktan algılama 20.yy. başlarında 1. ve 2. Dünya savaşı sırasında keşif ve hedefleme maksatlı yaygınlaşmıştır.

NASA ve U.S. Geological Survey (USGS) tarafından başlatılan Landsat programı, modern uzaktan algılamada önemli bir dönüm noktası olmuştur. Landsat uyduları, tarım, ormancılık, arazi kullanım planlaması ve çevresel izleme dahil olmak üzere çeşitli uygulamalar için Dünya yüzeyinin çok bantlı görüntülerini yakalamak üzere tasarlanmış ve Landsat 1 1972'de bu amaçla fırlatılan ilk uydu olmuştur. Bu tarihten sonra birçok ülke ve kuruluş gözlem ve radar gözlem uydularını yörüngeye fırlatarak bu alandaki teknolojik gelişmelere imza atmıştır.

1975'te Avrupa Uzay Ajansının (ESA) kurulması ile uzaktan algılama çalışmaları hız kazanmıştır. Birçok amaçla yörüngeye fırlatılan uyduları 2014 Copernicus programının bir parçası olan Sentinel uydu serisi takip etmiştir. Bu uydular, çevresel izleme, kaynak yönetimi ve afet müdahalesi gibi kapsamlı dünya gözlemleri için veri sağlamaktadır.

Uzaktan algılama teknolojisi, meteoroloji, jeoloji, hidroloji, ekoloji, oşinografi, buzul bilimi, coğrafya gibi yer bilimleri gibi çoğu yer bilimleri dahil binlerce farklı kullanım durumunda çok çeşitli disiplinlerde ve askeri uygulamalarda kullanılmaktadır. Bazı tipik uzaktan algılama örnekleri şunları içerir:

CBS ve uzaktan algılama: coğrafi bilgi sistemi, coğrafi veya mekânsal verileri yakalamak, depolamak, yönetmek, analiz etmek ve sunmak için tasarlanmış bir sistemdir. Bu iş akışında uydu, uzaktan algılama önemli bir mekânsal veri kaynağı sağlamaktadır. Uzaktan algılama ve CBS, dünyadaki hemen hemen her coğrafi konumdan verileri toplamak, depolamak, analiz etmek ve görselleştirmek için birlikte çalışır.

Sulama ve toprak nemi izleme ve yönetimi gibi tarımda uzaktan algılama çalışmalarında kullanılmaktadır.

Hava sistemlerinde rüzgâr hızı ve yönü gibi meteorolojik olayların yanı sıra yağış yoğunluğu ve konumu da ölçmede kullanılmaktadır. Diğer bir uygulama hava trafik kontrolüdür.

Aktif yanardağları izlemek için termal algılama ve orta kızılötesi algılama kullanır.

Olası heyelanları tahmin etmek ve erken uyarılar sağlamak için interferometri uzaktan algılama tekniğini kullanır.

Lidar teknolojisiyle bitki örtüsünün izlenmesi, silahların tespiti ve mermilerin lazerle aydınlatılmış yön tayini ve atmosferdeki çeşitli kimyasalların konsantrasyonunu tespit etmek ve ölçmek için de kullanılabilir.

Kara habitat özelliklerini simüle etmek ve muhtemel güzergahları belirlemek amacıyla, trafik yönetiminde ve karayolu departmanlarında çalışan görüntü ve arazi uzmanları tarafından topolojik haritalar oluşturmak için kullanılmaktadır.

Depremlerin oluşturduğu hasarı ölçmek amacıyla afet öncesi ve sonrası üretilen görüntüler UA ve CBS teknolojileri yardımı ile işlenmekte ve analiz edilmektedir. Bu, kurtarma ekiplerine hayati bilgiler temin etmektedir.

Uydular, sonar ve ultrason ölçümlerinden kaynaklanan verileri kullanarak, kıyı haritalama, erozyon kontrolü, okyanus kaynaklarının daha iyi yönetimi, doğal felaketlerin etkilerinin değerlendirilmesi ve önceden kullanılan felaket müdahale stratejilerinin oluşturulması için kullanılmaktadır. Afet olaylarından sonra yapılan çalışmalarda, kentsel büyümenin çevresel zararını minimize etmede ve doğal kaynakların en iyi şekilde korunması konularında karar vericiler tarafından kullanılmaktadır.

Petrol ve doğalgaz sektöründe, kuyu saha planlaması altyapısının değerlendirilmesiyle yukarı ve aşağı yönlü gaz ve petrol operasyonları için vazgeçilmez bir araçtır. Spektral analiz, yüzey çıkıntılarının ve yüzeydeki hidrokarbon sızıntılarının değerlendirilmesi için büyük önem taşımaktadır.

2.5.1. Uzaktan algılama verilerinin elde edilmesi

Uzaktan algılama yöntemleri ile veri edinimi bir süreçtir. Bu süreçte verinin edinim şekli, hızını, kalitesini ve kullanım fonksiyonlarını etkileyen birçok etken bulunmaktadır. Bu süreçte veri edinimini etkileyen başlıca adımlar şu şekildedir;

Veri Toplama Platformunun Seçimi: İlk adım, verilerin toplanacağı platformun seçimidir. Bu, uydular, hava uçakları veya yer istasyonları gibi çeşitli kaynaklardan gelebilir. Platformun seçimi, hangi tür verilerin toplanacağına ve ne kadar ayrıntıda olacağına bağlı olarak yapılır.

Veri Toplama Sensörlerinin Seçimi: Her platform, belirli bir sensör veya cihaz setini kullanır. Örneğin, elektromanyetik spektrumun farklı bölgelerini ölçmek için farklı türde kameralar ve spektrometreler kullanılır. Bu sensörler, farklı türde verilerin elde edilmesine olanak tanır.

Veri Toplama Süreci: Seçilen platform ve sensörler, hedef bölgeye yönlendirilir. Verilerin toplanması genellikle sensörlerin belli bir yükseklikten veya uzaklıktan hedefe bakmasını içerir. Bu süreçler, genellikle önceden belirlenmiş rota ve zamanlamalara tabidir.


Veri İşleme ve Analiz: Veriler toplandıktan sonra, bunlar analiz edilir. Bu analiz, görüntülerin işlenmesi, spektral analizlerin yapılması veya diğer özel işlemleri içerebilir. Bu aşama, verilerin kullanıcıların ihtiyaçlarına göre dönüştürülmesini sağlar.

2.5.2. Algılayıcı tipleri

Uzaktan Algılama biliminde kullanılan ve geliştirilen algılayıcılar Görsel 2.2’te görüleceği üzere iki temel gruba ayrılmaktadır(http-5):

1-Pasif Algılayıcılar: Bir nesne ya da çevredeki alan tarafından yansıtılan veya yayılan radyasyonu toplayarak harici uyaranlara yanıt verir. Pasif sistemlerle ölçülen en yaygın radyasyon kaynağı yansıyan güneş ışığıdır. Pasif sensörlerin popüler örnekleri arasında şarj bağlantılı cihazlar, film fotoğrafçılığı, radyometreler ve kızılötesi bulunur.


2-Aktif Algılayıcılar: Verileri toplamak için dahili uyaranlar kullanır, cisimleri ve yeryüzünü taramak için enerji yayar ve bir sensör hedeften yansıyan enerjiyi ölçer. Örneğin, Lidarlar ve Radarlar nesnelerin konumunu ve hızını belirlemek için gidiş ve geri dönüş arasındaki zaman gecikmesini ölçen tipik aktif uzaktan algılama sistemleridir. Toplanan veriler daha sonra çeşitli tescilli ve açık kaynak uygulamalarında bulunan uzaktan algılama donanımı ve bilgisayar yazılımı ile işlenir ve analiz edilir (http-4)



Görsel 2.2. Algılayıcı tipleri

2.6. Uyduların yörüngeleri ve tarama alanı

Uyduların dünya veya başka bir cisim etrafında düzenli olarak izlediği yola yörünge adı verilir. Yörüngeler Şekil 2.7’deki gibi döndükleri yönler, yüksekliklerine ve konumlarına göre üç sınıfa ayrılmaktadır:



Şekil 2.7. Uyduların yörünge tipleri

1- Alçak Yörünge Uyduları: Dünya yüzeyine nispeten yakın bir yörüngedir. Normalde dünyaya göre 160 km -1000 km arası yükseklikte konumlanır. Bu diğer yörüngelerle karşılaştırıldığında düşüktür, ancak yine de Dünya yüzeyinin çok üzerindedir.

Karşılaştırıldığında, çoğu ticari uçak yaklaşık 14 km'den çok daha yüksek irtifalarda uçmaz, bu nedenle en yakın uydudan bile bunun on katından fazladır.

Dünya'ya olan yakınlığı onu birkaç nedenden dolayı yararlı kılıyor. Yüzeğe yakın olması, daha yüksek çözünürlüklü görüntüler çekmesine izin verdiği için, uydu görüntülemeye en yaygın olarak kullanılan yörüngedir. Ayrıca, astronotların oraya daha kısa mesafeden gidip gelmeleri daha kolay olduğundan, Uluslararası Uzay İstasyonu (ISS) için kullanılan yörüngedir. Bu yörüngedeki uydular saniyede yaklaşık 7,8 km hızla hareket eder; bu hızda, bir uydunun Dünya'yı çevrelemesi yaklaşık 90 dakika sürer, yani ISS Dünya'nın etrafında günde yaklaşık 16 kez dolaşır.

2- Orta Yörünge Uyduları: Yörüngeleri dünyadan 5bin-15bin km yükseklikte konumlanan uydulardır. Tarama alanları Alçak Yörünge Uydularına göre daha geniştir.

3- Yerdurağan Yörünge Uyduları: Dünya ile tam olarak aynı hızda seyahat ederek, Dünya'nın dönüşünü takiben (23 saat 56 dakika 4 saniye) Dünya'yı ekvatorun üzerinde batıdan doğuya çembere alır. Bu uyduların sabit bir konum üzerinde "sabit" görünmesini sağlar. Dünya'nın dönüşüne tam olarak uyması için GEO uydularının hızı,

35 786 km yükseklikte saniyede yaklaşık 3 km olmalıdır. Bu, birçok uyduya kıyasla Dünya yüzeyinden çok daha uzaktır.


Yerdurağan uydular, dünya yüzeyinde belirli bir alanı sürekli gözlemleyecek veya tarayacak mesafe ve konumda bulunan uydulardır. Bu sayede, Dünya üzerindeki bir anten, hareket etmeden her zaman aynı uydunun yönüne odaklanabilir. Örneğin, hava durumu izleme uyduları da bu tür uyduları kullanmaktadır. Bu sayede belirli bölgeleri sürekli olarak gözlemleyerek hava eğilimlerinin nasıl geliştiğini gözlemleyebilirler.

4-Tarama Alanı: Uydular yörüngesinde ilerlerken, algılayıcılar yer yüzünün bir bölümünü taramaktadır. Uydu bu yörünge boyunca ilerlerken taradığı bölgeye “tarama alanı” denmektedir (http-5).

2.7. Veri işleme ve görsel yorumlama

Uzaktan algılanan görüntüler ayrıca bir bilgisayarda piksel dizileri (resim öğeleri) olarak temsil edilebilir, her piksel bir dijital sayıya karşılık gelir ve bu pikselin görüntüdeki parlaklık seviyesini temsil eder. Bu durumda veriler dijital formattadır. Bu tür dijital görüntüler, piksellerin satırlar ve sütunlar halinde düzenlendiği raster görüntüler olarak adlandırılır.


Dijital bir görüntüde yakalanan elektromanyetik enerjinin büyüklüğü, pozitif dijital sayılarla temsil edilir. Dijital sayılar, 0'dan seçilen 2 kuvvetine kadar değişen ikili rakamlar (bitler) biçimindedir.



Şekil 2.8. Görüntü piksel değerleri

Dijital bir görüntünün çözünürlüğü, piksel değerinin aralık büyüklüğüne (yani parlaklık aralığına) bağlıdır. 2 bitlik bir görüntüde, maksimum aralık, 0 ile 3 arasında değişirken, 8 bitlik bir görüntüde aralık, daha yüksek çözünürlüklü bir görüntü olan, 0 ile 255 arasında değerler almaktadır(http-6).

Bir görüntü sisteminde kaydedilen detayların ayırt edilebilirlik ölçütüne çözünürlük denir (Görsel 2.9).




Şekil 2.9. Görüntü piksel yoğunluğu

Uydu görüntüleri dört farklı çözünürlük sınıfında incelenmektedir. Bunlar;

2.7.1. Radyometrik çözünürlük

Bir görüntüdeki piksellerin düzenlenmesi geometrisini oluştururken, radyometrik özellikler ise o görüntüdeki gerçek bilgi içeriğini tanımlamaktadır. Bir film veya sensör tarafından bir görüntü her alındığında, elektromanyetik enerjinin büyüklüğüne olan duyarlılığı radyometrik çözünürlüğü belirler. Bir görüntüleme sisteminin radyometrik çözünürlüğü, enerjideki çok küçük farklılıkları ayırt etme yeteneğini tanımlamaktadır.



Görsel 2.3. Radyometrik çözünürlük


Sensörlerin radyometrik çözünürlüğü ne kadar inceyse, yansıyan veya yayılan enerjideki küçük farklılıkları tespit etmede o kadar hassaslaşır (Görsel 2.3).

2.7.2. Spektral çözünürlük

Spektral çözünürlük, bir algılayıcının kaç tane spektral bant kaydettiğini ifade eder. Ayrıca her bir bandın ne kadar “geniş” olduğuna veya tek bir bant tarafından kapsanan dalga boyları aralığına göre tanımlanır. Siyah beyaz fotoğraflar yalnızca görünür dalga boylarını kapsayan 1 bant, renkli (RGB) görüntüler 3 bant, Planet Scope’da 4 bant ve Sentinel-2’de toplam 12 bant bulunmaktadır. Örneğin, Sentinel-2 uydu görüntüsü Planet Scope göre daha düşük mekânsal çözünürlüğe sahip olmasına rağmen daha yüksek spektral çözünürlüğe sahiptir.

2.7.2.1. Mekânsal çözünürlük

Bu çözünürlük türü genellikle tek bir pikselin bir tarafının uzunluğu olarak ifade edilir. Örneğin Landsat, 30 metre uzaysal çözünürlüğe sahipken Sentinel 10 m çözünürlüğe sahiptir. Başka bir deyişle, 30 metre mekânsal çözünürlüğü olan bir görüntü tek bir pikselin zeminde 30 metre genişliğinde bir alanı taradığı anlamına gelir (Şekil 2.10).



Şekil 2.10. Mekânsal çözünürlük

2.7.3. Zamansal çözünürlük

Algılayıcıların yörünge üzerinde ilerlerken aynı alandan ikinci görüntüyü alma süresi ile ölçülmektedir. Örneğin, Sentinel-2 uydusunun zamansal çözünürlüğü 5 gün iken Planet Scope görüntüsünün 1 gün veya Göktürk-2 uydusunun 2.5-5 gündür.

2.8. Görüntü elde etme

Bu bölümde görüntünün uydu algılayıcısı tarafından kaydedilmesinden sınıflandırmada kullanılacak hale gelmesi aşamaları başlıklar halinde verilmiştir.

2.8.1. Ön işleme


Herhangi bir veri analizi veya görüntü yorumlaması yapılmadan önce, ham verilerin genellikle düzeltilmesi ve hatalara karşı ayarlanması gerekir. Ön İşleme, uzaktan algılanan verilerde meydana gelebilecek radyometrik ve geometrik hataları düzeltmek için kullanılan tüm teknikleri tanımlamak için kullanılan genel terimdir. Görüntüler elde edildiğinde, verilere çeşitli türlerde hatalar eklenebilir. Bu hatalar sensör hareketi, yörünge özellikleri ve atmosferik ve çevresel koşullardan kaynaklanabilir.

Ön işleme, bozulmaları ve hataları düzeltmek için ham (veya en az işlenmiş) verilerin ilk işlenmesini içerir. Bu hatalar radyometrik ve geometrik hatalar olarak kategorize edilebilir.

2.8.2. Geometrik düzeltme


Tüm ham havadan görüntüler, bir dereceye kadar geometrik bozulma içerir. Bu bozulmalar sensör konumundaki farklılıklar, görüntüler kaydedilirken Dünya'nın kendi eksenini üzerinde dönmesi, toprak eğriligi ve son olarak arazi etkileri (rölyef yer değiştirme) nedeniyledir. Bazı bozulmalar öngörülebilirdir ve kolayca düzeltilebilirken diğerleri daha karmaşıktır ve bozucu etkenlerin verilerden kaldırılması zordur.

Geometrik düzeltme işlemlerinin amacı, bozulmaları telafi etmek ve nihayetinde yüksek düzeyde geometrik bütünlüğe sahip düzeltilmiş bir görüntü üretmektir. Görüntüler geometrik bozulmalar için düzeltilmezse, belirli bir pikselin x, y konumu doğru coğrafi konumda olmayacaktır. Görüntünün geometrik olarak düzeltilmesi için yeniden örneklemek gerekmektedir (Şekil 2.11).



Şekil 2.11. Geometrik düzeltme

Yeniden örnekleme, coğrafi verileri bilinen bir koordinat sistemine hizalama işlemidir, böylece görüntülenebilir ve diğer coğrafi verilerle analiz edilebilir. Bu şekilde, verileri kaydırmayı, döndürmeyi, ölçeklemeyi, eğiltmeyi içerebilir. Birçok tarama veri kümesinin, diğer coğrafi verilerle görüntülenebilmesi veya analiz edilebilmesi için önce coğrafi referansa sahip olması gerekir. Örneğin, tarihsel hava fotoğrafları ve haritalar ücretsiz orta çözünürlüklü görüntü sağlayıcılar (EarthExplorer, sentinel-hub vs.) aracılığıyla edinilebilir, ancak bu görüntüler genellikle coğrafi referanslı değildir.



Görsel 2.4. Yer kontrol noktası

Coğrafi referans yapmak istediğiniz bir tarama elde ettiğinizde, referans verileri elde etmeniz gerekir. Bu, bilinen bir koordinat sistemine sahip bir veri katmanı veya sahada toplanan veriler olabilir. Bilinen bir koordinat sistemine sahip bir katman kullanıyorsanız, Yer Kontrol Noktalarını (YKN) belirlemeniz gerekir. Yer kontrol noktaları, Görsel 2.4'deki gibi bir görüntüde kolayca tanımlanabilen, bilinen koordinatlara sahip konumlardır. Veri katmanlarında kolayca tanımlanabilen yol kavşakları, taş duvar sınırları, bina köşeleri ve yalnız ağaçlar bazı iyi YKN örnekleridir. Geçmiş görüntülerle çalışıyorsanız, zaman içinde hareket etmemiş ve bozulmaya uğramamış yer kontrol noktaları seçmeniz gerekir. GPS ile sahada yer kontrol noktaları da toplanabilir. Kontrol noktaları, veri kümeleri arasında bir bağlantı oluşturur ve görüntüleri coğrafi referanslamaya yardım eder.

2.8.3. Radyometrik düzeltme


Piksel değerlerinin kalibre edilmesi ve değerlerdeki hataların düzeltilmesi için radyometrik düzeltme yapılmaktadır (Görsel 2.5). Süreç, uzaktan algılanan verilerin

yorumlana bilirligini ve kalitesini iyileştirir. Radyometrik düzeltmeler ve kalibrasyon, belirli bir süre boyunca birden fazla veri setini karşılaştırırken özellikle önemlidir.


Uçak veya uydulardaki sensörlerin kaydettiği enerji, yayılan veya yerdeki bir yüzeyden yansıtılan gerçek enerjiden farklı olabilir. Bu, sensör tarafından gözlemlenen enerjiyi etkileyebilecek güneşin azimutu ve yüksekliği ve atmosferik koşullarından kaynaklanmaktadır. Bu nedenle, gerçek veya gerçek zemin ışıma veya yansıma değerlerini elde etmek için radyometrik hataların hesaba katılması gerekir. Uydu tabanlı sensörler tarafından tespit edilen veya ölçülen ışıma, dünya yüzeyinden yansıyan radyasyonu ve atmosferdeki parçacıklar tarafından saçılan radyasyonu içerir. Sensörlerin kaydettiği enerjinin neredeyse tamamı atmosferden bir şekilde etkilenir.

Radyometrik düzeltmeye dört ana hatayı gidermek için kullanılmaktadır;

1. Algılayıcıdan kaynaklanan sistematik hatalar
2. Güneş ışınının geliş açısından kaynaklı hatalar
3. Yeryüzünün topografyası ve yüzeyinden kaynaklı hatalar
4. Atmosferik şartlardan kaynaklı hatalar: sis, bulut vs.



a) Orijinal görüntü



b) Radyometrik düzeltme uygulanmış görüntü

Görsel 2.5. Radyometrik düzeltme-2

2.8.4. Görüntü keskinleştirme (Pansharpening)

Bu teknik, yüksek çözünürlüklü pankromatik (tek renkli) görüntülerle daha düşük çözünürlüklü multispektral (çok renkli) görüntüleri birleştirerek hem spektral ayrıntıları hem de uzamsal ayrıntıları korumayı amaçlar.

Pansharpening işlemi, genellikle uzaktan algılama uydularından elde edilen görüntüler üzerinde uygulanır. Bu görüntülerin iki ana türü vardır: pankromatik görüntüler, yüksek uzamsal çözünürlüğe sahiptir ancak tek bir renk kanalını temsil

ederler; multispektral görüntüler ise daha fazla renk kanalına sahiptir, ancak daha düşük uzamsal çözünürlüğe sahiptir.

Örneğin; Landsat 8'in multispektral bantları 30m uzamsal çözünürlüğe sahiptir fakat, 15 m uzaysal çözünürlüğe sahip pankromatik bir bant da toplanabilir. Sentinel-2 ise pankromatik bantı yardımı ile tüm bantların içeren 10 m çözünürlüklü multispektral bant elde edilebilir.

Literatürde çok sayıda keskinleştirme yöntemi bulunmaktadır. Çalışmada kullanılan HPF (High Pass Filter) ve P+XS keskinleştirme yöntemleri detaylı incelenecektir.

2.8.4.1. HPF (High Pass Filter) keskinleştirme yöntemi

Uzaktan algılama çalışmalarının ilk yıllarında yüksek uzamsal çözünürlüklü spektral bantlar ile daha düşük çözünürlüklü bantların bir karışımının, görüntü bilgi içeriğinden ödün vermeden veri hızlarını azaltmanın kabul edilebilir bir yolu olabileceği öne sürülmüştür (Colvocoresses, 1977). Bu ihtiyaca binaen yapılan en sade yöntemlerden birisi de Yüksek Geçirgenli Filtre (High Pass Filter-HPF) yöntemi olmuştur.

Renk tabanlı bir yöntem olan HPF yöntemi, daha yüksek çözünürlüklü girdi pankromatik görüntünün mekânsal yapısının detaylarını bir yüksek geçirgen filtre yardımıyla iyileştirmektedir. İyileştirilen görüntünün bilgisi girdi çok bantlı görüntünün bantlarına aktarılır ve keskinleştirilmiş Pan görüntü oluşturulur (Schowengerdt, 1980). Bu sayede yalnızca çoklu görüntüler mekânsal olarak yeniden yapılandırılmaz aynı zamanda piksellerin yansıma değerlerinin ve renklerinin geliştirilmesini sağlar.

HPF yöntemi çalışma içerisinde 20 m ve 60 m mekânsal çözünürlüklü Sentinel-2 bantlarının 10m'ye keskinleştirilmesinde kullanılmıştır.

2.8.4.2. P+XS keskinleştirme yöntemi

P + XS kısaltmasının Pankromatik ve Multispektral görüntüleri ifade etmektedir. P + XS yöntemi, daha yüksek çözünürlüklü görüntünün tüm kenarlarını her bir düşük çözünürlüklü multispektral bantla hizalayarak daha yüksek çözünürlüklü görüntünün geometri bilgisini sunmaktadır. Birleştirilmiş görüntünün spektral bilgilerini elde etmek için, yöntem, farklı spektral bantlarda alınan görüntülerin ortak geometrik bilgileri paylaştığını ve daha yüksek çözünürlüklü görüntünün, yüksek çözünürlüklü multispektral

bantların doğrusal bir kombinasyonu olarak yaklaşık olarak tahmin edilebileceğini varsayılmıştır (Ballester vd., 2006; He vd., 2012, Gasparović ve Jogun, 2018). (Gašparović ve Jogun, 2018), her bir S2 bandı, benzer spektral özelliklere sahip yüksek çözünürlüklü bir Planet Scope bandıyla birleştirilmiştir. Bu nedenle Tablo 2.2’de eşleştirildiği gibi 10 m’lik S2 bantları 2, 3, 4, 8, sırasıyla yüksek çözünürlüklü Planet Scope bantları 1, 2, 3, 4’e göre keskinleştirilmiştir. Ayrıca, 20 m Sentineş-2 B8A, Planet Scope B4’e göre keskinleştirilmiştir. Buna göre, 20 m mekânsal çözünürlüklü Sentinel-2 5, 6, 7, 11, 12 bantları denklem tarafından verilen sentezlenmiş bant (S) temelinde keskinleştirilmiştir:

$$S = \frac{B3+B4}{2} \quad (2.4)$$

B3 ve B4, sırasıyla Planet Scope bant 3 ve bant 4’ü temsil etmektedir.

Tablo 2.2. S2 bantlarının keskinleştirilmesinde pankromatik bant olarak kullanılan PS bantları

Sentinel-2		Planet Scope	
Mekansal Çözünürlük	Bantlar	Bantlar	Mekansal Çözünürlük
10 m	B2	B1	3 m
	B3	B2	
	B4	B3	
	B8	B4	
20 m	B8A	B4	3 m
	B5	$S = \frac{B3+B4}{2}$	
	B6		
	B7		
	B11		
	B12		

2.9. Yer gözlem uydu sistemleri

Birçok amaç için çeşitli mesafelerden dünyayı gözlemleyen uzaktan algılama uyduları yardımı ile yer yüzeyi hakkında farklı fotografik verilerin elde edilmesi kolaylaşmıştır. Bu veriler ile yeryüzündeki çeşitli nesnelerin ve alanların izlenmesi doğal kaynaklarımızın takibi, doğal afetlerin, çevre kirliliğinin tespiti, şehircilik çalışmaları veya meteorolojik çalışmalar gibi uygulamada kullanılmaktadır.

Topografik ve tematik haritaların üretilmesi ve mevcut haritaların güncellenmesi süreçlerinde, uzaktan algılama görüntülerinin hızı, doğruluğu ve maliyeti açısından birçok avantajı bulunmaktadır. Yüksek çözünürlüklü uyduların sağladığı geniş gözlem

alanı, uydu alıcılarının hızlı hareket kabiliyeti ve kullanılan spektral bant sayısı sayesinde büyük miktarda veri üretmek mümkün olmaktadır.

Uzaktan algılama çalışmalarına altlık teşkil edecek farklı türden veri üreten uydulara; SENTINEL, PLANET SCOPE, LANDSAT, JERS-1, NOAA, SPOT, IRS-1C uydularını örnek gösterebiliriz.

2.9.1. Sentinel-2

Sentinel-2 misyonu, birbirinden 180° zıt konumlandırılmış, güneş-senkron düzen içinde yörüngede dönen bir çift kutupsal yörüngeli uydudan oluşmaktadır. Birincil amacı arazi yüzeyi koşullarındaki değişiklikleri izlemektir. Özellikle, bu görev, 290 kilometrelik bir tarama alanı genişliğine ve yüksek bir frekansına sahiptir; bir uydu, her 10 günde bir toplamda iki uydu açık gökyüzü altında çalışır durumdayken 5 günde bir, aynı noktayı ziyaret etmekte ve taramaktadır. Bu frekans, Dünya yüzeyindeki değişikliklerin etkili bir şekilde izlenmesine olanak tanır.

Sentinel-2, 13 spektral bandı örnekleyen bir optik cihaz yükü taşımaktadır: 10 m'de dört bant, 20 m'de altı bant ve 60 m uzaysal çözünürlükte üç bant bulunmaktadır.

Bu uydu çifti, mevcutta görev yapan Landsat, Spot gibi görüntü verilerinin sürekliliğini sağlayarak çok bantlı gözlemlere katkıda bulunmaktadır. Bu uydular, tarımsal ve kentsel arazilerin yönetimi, mekânsal planlama, çevresel izleme, ormancılık ve bitki örtüsü izleme, küresel mahsul izlemesi, afet kontrolü ve izlenmesi (sel, yangın, heyelan, fırtına, deprem vb.), insani yardım operasyonları, risk haritalaması, deniz ve kara sınır güvenliği dahil olmak üzere çeşitli hizmet ve uygulamaları desteklemek için kullanılmaktadır.

Dünya'dan yansıyan güneş ışığını toplayan Sentinel-2 pasif olarak çalışmaktadır. Uydu yörünge yolu boyunca hareket ettikçe cihaz tarafından yeni veriler elde edilir. Gelen ışık demeti bir ışın ayırıcı aracılığıyla bölünür ve cihaz içindeki iki ayrı odak düzlemi düzeneğine odaklanmaktadır; biri Görünür ve Yakın Kızılötesi (VNIR) bantlar için, diğeri ise Kısa Dalga Kızılötesi (SWIR) bantlar içindir. Her bandın bireysel dalga boylarına spektral olarak ayrılması, dedektörlerin üstüne monte edilen şerit filtreler tarafından gerçekleştirilir.

2.9.1.1. Uydu teknik özellikleri

Sentinel-2 uydusu yaklaşık olarak 1,2 ton ağırlığında iki eş uydudan oluşmaktadır (Görsel 2.6). Bu iki uydu da Avrupa'nın VEGA fırlatma aracıyla gönderilmiştir. Bu uyduların pilleri ve iticileri, ömrünün sonuna kadar, manevralar dahil olmak üzere 12 yıllık operasyon süresini desteklemek üzere tasarlanmıştır.



Görsel 2.6. Sentinel-2 yapım aşaması

İki aynı model Sentinel-2 uydusu, güneşe senkronize bir yörüngede, tam olarak 786 kilometre yükseklikte bulunur ve birbirine 180 derece farkla yerleştirilmiştir. Her bir Sentinel-2 uydusunun yörünge pozisyonları, çift frekanslı Global Navigasyon Uydu Sistemi (GNSS) alıcıları ile hassas bir şekilde ölçülür. Bu yörünge hassasiyeti, özel bir sistem tarafından sürdürülmektedir (Görsel 2.7).




Görsel 2.7. Sentinel-2 uzay aracının şematik görünümü

Sentinel-2 uydu sistemi, Almanya merkezli Astrium GmbH tarafından yönetilen bir endüstri konsorsiyumu tarafından geliştirilmiştir. MultiSpectral Enstrüman (MSI) ise Fransa merkezli Astrium SAS tarafından üretilmiştir.

MSI, Dünya'dan yansıyan güneş ışığını pasif bir şekilde toplayarak çalışır. Uydu, yörünge üzerinde hareket ettiğinde sürekli olarak yeni veriler elde eder. Gelen ışık demeti, bir filtre tarafından ayrıştırılır ve enstrüman içinde iki ayrı odak düzlemine yönlendirilir. Bu odak düzlemlerinden biri Görünür ve Yakın Kızılötesi (VNIR) bantları için kullanılırken, diğeri Kısa Dalga Kızılötesi (SWIR) bantları için tasarlanmıştır. Her bantın özgün dalga boylarına göre spektral ayrımı, dedektörlerin üzerine yerleştirilmiş şerit filtrelerle gerçekleştirilir(http-7).

2.9.1.2. Spektral çözünürlük

Uydu görüntülerinde spektral çözünürlük, görüntülerin farklı dalga boylarındaki (veya spektral bantlardaki) ayrıntıları ayırt etme yeteneğini ifade etmektedir. Çalışmada farklı ve avantajlı yönlerinin kıyaslamasının daha iyi yapılabilmesi için Ssentinel-2 ve Planet Scope görüntülerinin spektral çözünürlükleri bant genişlikleri Şekil 2.12’de verilmiştir. S2 bantları, B5, B6, B11 ve B12, PS bantlarının hiçbirleriyle örtüşme göstermemiştir.



Şekil 2.12. PS ve S2 bantlarının spektral çözünürlüğü ve dalga boyu aralığı

2.9.1.3. Radyometrik çözünürlük

Radyometrik çözünürlük, cihazın ışık yoğunluğu veya yansımadaki farklılıkları ayırt etme kapasitesidir. Radyometrik çözünürlük ne kadar yüksek olursa, algılanan görüntü o kadar doğru olur.

Radyometrik çözünürlük genellikle 8 ile 16 bit aralığında bir sayı olarak ifade edilmektedir. MSI cihazın radyometrik çözünürlüğü 12 bit olup bu ölçümler yansımalarla dönüştürülerek 16 bit tam sayılar olarak saklanmaktadır. Ayrıca cihaz görüntünün 0 ile 4095 potansiyeli ışık yoğunluğu değere aralığında elde edilmesini sağlamaktadır. Sentinel-2'nin bantlarına ait dalga boyu ve bant genişlikleri Tablo 2.3, Tablo 2.4, Tablo 2.5'te ki gibidir ([http-7](http://7)).

Tablo 2.3. Sentinel-2 10 m, radyometrik çözünürlük ve bant genişlikleri.

Bant Numarası	S2A		S2B		L_{ref} (W m ⁻² sr ⁻¹ µm ⁻¹)	SNR @ L_{ref}
	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)		
2	496.6	98	492.1	98	128	154
3	560.0	45	559	46	128	168
4	664.5	38	665	39	108	142
8	835.1	145	833	133	103	174

Tablo 2.4. Sentinel-2 60 m, radyometrik çözünürlük ve bant genişlikleri.

Bant Numarası	S2A		S2B		L_{ref} (W m ⁻² sr ⁻¹ µm ⁻¹)	SNR @ L_{ref}
	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)		
1	443.9	27	442.3	45	129	129
9	945.0	26	943.2	27	9	114
10	1373.5	75	1376.9	76	6	50

Tablo 2.5. Sentinel-2 20 m, radyometrik çözünürlük ve bant genişlikleri.

Bant Numarası	S2A		S2B		L_{ref} (W m ⁻² sr ⁻¹ µm ⁻¹)	SNR @ L_{ref}
	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)	Merkezi Dalgaboyu (nm)	Bant Genişliği (nm)		
5	703.9	19	703.8	20	74.5	117
6	740.2	18	739.1	18	68	89
7	782.5	28	779.7	28	67	105
8a	864.8	33	864	32	52.5	72
11	1613.7	143	1610.4	141	4	100
12	2202.4	242	2185.7	238	1.5	100

2.9.1.4. Veri formatı

Sentinel-2 Level-1C ve Level-2A ürünleri, JPEG2000 formatındaki görüntü verileri, kalite göstergeleri (örneğin kusurlu piksel maskesi), yardımcı veriler ve meta veriler dahil olmak üzere Sentinel-SAFE formatında kullanıcılara sunulmaktadır.

SAFE formatı, ESA Dünya Gözlem arşivleme tesisleri içerisinde verilerin arşivlenmesi ve iletilmesi için ortak bir format görevi görecektir. SAFE formatı, ikili veri formatındaki görüntü verilerini ve XML'deki ürün meta verilerini içeren bir klasörü sarar. Bu esneklik, formatın tüm Sentinel ürünlerini temsil edecek kadar ölçeklenebilir olmasını sağlar.

ESA tarafından son kullanıcıya sunulan veri setinde ayrıca;

- Ürünün fiziksel organizasyonunu ve içeriğini açıklayan, XML formatındaki ürün meta veri dosyası
- XML'deki genel ürün bilgilerini tutan bir manifest.safe dosyası
- JPEG2000 formatındaki görüntü verilerinin (granüller/döşemeler) yanı sıra kalite göstergelerini (kalite raporları vb.) içeren bir GRANÜL alt klasörü
- Veri şeridi düzeyinde bilgi içeren bir DATASTRIP alt klasörü
- Ürüne gömülebilen yardımcı dosya setini içeren bir AUX_DATA alt klasörü
- Ürün bileşenlerini açıklayan XSD şemalarını içeren rep-info alt klasörü

- INSPIRE meta veri düzenlemesini temel alan bir meta veri dosyası olan bir INSPIRE XML dosyası
- Ürünün ana içeriğinin kolayca görüntülenmesini sağlayan bir ürün sunum dosyası içeren bir HTML alt klasörü de bulunmaktadır (http-7).

2.9.2. Planet Scope

Planet Scope uydu takımıyıldızı, bir uydu grup aynı veya benzer özellikler içeren uydunun aynı yörüngeye belirli aralıklarla fırlatılmasından oluşmaktadır. Her Planet Scope uydusu CubeSat 3U form faktörüne sahiptir (10 cm x 10 cm x 30 cm). Yaklaşık 200 uydudan oluşan tam Planet Scope takımıyıldızı, her gün Dünya'nın kara yüzeyinin tamamını görüntüleyebilmektedir (günlük 200 milyon km² toplama kapasitesine eşittir). Bu kapasite, yörüngedeki uydu sayısına göre ve mevsim boyunca değişmektedir, çünkü kış aylarında güneş ışığının olduğu saatlerin azalması nedeniyle uydular kuzey yarımkürede daha az görüntü almaktadır.

Tüm Planet Scope görüntüleri 12 bit olarak toplanmakta ve uyduda 12 bit olarak depolanmaktadır. Radyometrik düzeltme yeryüzündeki işleme sırasında yapılır ve tüm görüntüler 16 bit dinamik aralığını ölçeklenir. Ayrıca ofset düzeltme, düz alan düzeltme, kamera edinme parametresi düzeltmesi ve mutlak kalibrasyon gibi radyometrik ve sensör kalibrasyonları bu aşamada yapılmaktadır(http-8).

Planet Scope bantları B(mavi), (G)yeşil, (R)kırmızı görünür bantları ve NIR (yakın kızılötesi) bant olmak üzere dört banttan oluşmaktadır. Bantlara ait spektral ve mekânsal çözünürlükleri Tablo 2.6'da verilmiştir. PS görüntülerine ait ürün özellikleri Tablo 2.6'da verilmektedir.

Tablo 2.6. PS mekânsal çözünürlük ve bant dalga boyları

Planet Scope Bantları	Spektrum Bölgesi	Dalga Boyu (nm)	Mekânsal Çözünürlük
Bant-1	Mavi	455-515	3 m
Bant-2	Yeşil	500-590	
Bant-3	Kırmızı	590-670	
Bant-4	Yakın Kızılötesi	780-860	

Planet Scope görüntülerine ait bazı ürün özellikleri Tablo 2.7’de verilmiştir.

Tablo 2.7. PS ürün özellikleri

Ürün niteliği	Açıklama
Ürün Bileşenleri ve Formatı	Görüntü dosyası: GeoTIFF formatı Meta Veri Dosyası: XML Formatı Küçük Resim Dosyası: GeoTIFF formatı
Ürün Çerçeveleme	Sahne Tabanlı
Ortorektife Edilmiş Piksel Boyutu	3m
Düzeltilmiş Bit Derinliği	16 bit
Ürün Boyutu	475 km sahne yüksekliğinde 25 km
Yatay Datum	WGS84
Harita Projeksiyonu	UTM

2.10. İndeksler

Uydu görüntüleri farklı spektral ve mekânsal çözünürlüklü bantlardan oluşmaktadır. Bu bantlar formüle edilerek hedef çalışmaya yönelik üretilen indeksler aynı görüntüden farklı bilgiler edinmeyi sağlamaktadır. Çalışmanın bu bölümünde uzaktan algılama analiz tekniklerinden olan ve benzer çalışmalarda kullanılması çok tercih edilen bazı indeksler hakkında detaylı bilgi verilmiş ve tüm indekslerin formülleri ve indeks kodları bu bölümde listelenmiştir.

2.10.1. Normalize edilmiş fark bitki indeksi (NDVI)

Aşağıda gösterildiği gibi Normalleştirilmiş Fark Bitki Örtüsü İndeksi (NDVI: Normalized Difference Vegetation Index), formülünde NIR ve kırmızı kanalları kullanır.

$$NDVI = [(NIR - RED) / (NIR + RED)] = [(B08 - B04) / (B08 + B04)] \quad (2.5)$$

Sağlıklı bitki örtüsü (klorofil), diğer dalga boylarına kıyasla yakın kızılötesi (NIR) ve yeşil ışığı daha fazla yansıtır. Ancak kırmızı ve mavi ışığı daha fazla emer. Bu nedenle bitki örtüsü gözle yeşil olarak görünür. Gözle görünmeyen yakın kızılötesini alanda kaydedilen görüntüler bitki örtüsünü gözlemlemek açısından da güçlüdür. Planet Scope, Landsat ve Sentinel-2 gibi uydu sensörlerinin hepsi gerekli NIR ve kırmızı bantlara sahiptir (Tucker, 1979).

NDVI indek formülün sonucu -1 ile +1 arasında bir değer üretir. Kırmızı kanalda düşük yansımaya (veya düşük değerler) ve NIR kanalında yüksek yansımaya ise yüksek bir NDVI değeri vermektedir.

Genel olarak NDVI, sağlıklı bitki örtüsünü ölçmenin standartlaştırılmış bir yoludur. NDVI değerleri yüksek olduğunda daha sağlıklı bir bitki örtüsü olduğuna işaret etmektedir. NDVI düşük olduğunda bitki örtüsü sağlıklıdır, azdır veya hiç yoktur.

Formülde NDVI'nin yakın kızılötesinden (NIR) nasıl yararlandığı görülmektedir. Yani NIR bandını kırmızı olarak gösterecek şekilde yerleştirildiğinde renkli kızılötesi elde edilmektedir. Görsel 2.8'da görüldüğü gibi, gözle gözlemlenen yeşil tarım alanları NDVI haritasında yakın kızılötesi kırmızı alanlardır.



Görsel 2.8. Uydu görüntülerinin NDVI görünümü

NDVI haritaları kullanarak yeşil tarım arazilerini tespit etmek çok kolaydır.

2.10.2. Fark bitki indeksi (DVI)

Tarımsal çalışmalarda çokça kullanılan bitki örtüsü endeksinden biri olan Farklı Bitki Örtüsü İndeksi (DVI: Difference Vegetation Index), bitki örtüsünün yoğunluğunu ölçmek amacıyla kullanılır. Genellikle toprak ve bitki örtüsünün ayrımını yapmak için kullanılan bu indeks, atmosfer veya gölgelerin yansımaya ve parlaklık farklarına odaklanmaz. Bu nedenle, DVI gölgeli bölgelerde toprakla bitki örtüsünü kesin bir şekilde ayırt etmede sınırlıdır (Esemen, 2011)

$$DVI = NIR - RED = (B08 - B04) \quad (2.6)$$

2.10.3. Toprakla dengelenmiş bitki indeksi (SAVI)

SAVI(Soil Adjustment Vegetation Index), bitki örtüsünün seyrek olduğu bölgelerde toprak parlaklığının etkisini ortadan kaldırmak için Normalleştirilmiş Bitki Örtüsü indeksini (NDVI) düzelten bir araçtır. SAVI, arazi örtü tiplerini birbirinden

ayırmak için varsayılan olarak 0,5 değeri tanımlanan bir toprak parlaklık düzeltme faktörünü (L) hesaplamaya dahil etmektedir. İndeks değeri R ve NIR değerleri arasındaki oran olarak hesaplanır(Huete, 1988; Miura et al., 1998)

$$SAVI = (NIR-R) / (NIR+R+L) * (1+L) \quad (L=0,5) \quad (2.7)$$

2.10.4. Basit oran indeksi (SR)

Basit Oran (SR: Simple Ratio) yöntemi, bitki örtüsü miktarını tahmin etmek için yaygın bir bitki örtüsü indeksidir. Atmosfer ve topografyanın etkilerini azaltan, NIR'de saçılan ve kırmızı bantlarda emilen ışığın oranıdır.

Değerler, geniş yaprak alanı indeksi veya yüksek gölgelik kapanması olan bitki örtüsü için yüksek; toprak, su ve bitkisiz alanlar için düşüktür. Değer aralığı 0 ile yaklaşık 30 arasındadır ve sağlıklı bitki örtüsü genellikle 2 ile 8 değerleri arasındadır. İndekste iki değişken bu şekilde formülleştirilmektedir;

$$RVI = NIR / RED \quad (2.8)$$

2.10.5. Gelişmiş bitki örtüsü indeksi (EVI)

Geliştirilmiş Bitki Örtüsü İndeksi (EVI: Enhanced Vegetation Index), NDVI ile benzer bir hesaplama algoritmasına sahip olsa da aynı zamanda atmosferdeki parçacıkların neden olduğu yansıyan ışık değişimlerini ve bitki örtüsü altındaki toprak yüzeyindeki bazı bozulmaları düzeltme yeteneğine sahiptir. Ayrıca, EVI, yüksek klorofil içeriğine sahip bölgeleri görüntülerken NDVI kadar kolay bir şekilde doygunlaşmaz. Bununla birlikte, EVI tüm sorunları çözemez. Bulutlar ve aerosoller genellikle yüzeyin uydu görüntüsünü tamamen engelleyebilir, güneş ışığı belirli pikselleri doyurabilir ve uydu cihazlarındaki geçici arızalar görüntüyü bozabilir(Huete et al., 2002).

EVI'nin hesaplama formülü aşağıdaki gibidir:

$$EVI = G * [(NIR-R) / (NIR + C1 * R - C2 * B + L)] \quad (2.9)$$

Burada, atmosferik düzeltilmiş veya kısmen düzeltilmiş (Rayleigh ve ozon emilimi) yüzey yansıması olduğunda L, gölgelik ayarlama terimidir ve C1, C2 aerosol direnç terimlerinin katsayılarıdır. Bu, mavi bantı kullanarak aerosol etkilerini düzeltmek içindir. Kırmızı bantta MODIS aracından türetilen bir ürün olan EVI, dünya genelinde bitki örtüsü koşullarının tutarlı mekânsal ve zamansal izlenmesi için kullanılır.

2.10.6. Dönüştürülmüş bitki örtüsü indeksi (TVI)

Dönüştürülen Bitki Örtüsü Endeksi (TVI: Transformed Vegetation Index), NDVI'nin karekökünü alarak negatif değerleri ortadan kaldırmaya ve NDVI histogramlarını dönüştürmeye çalışır. Ancak, sonuç her zaman NDVI ile aynı olmalıdır, bu nedenle istenen sonuç her zaman elde edilemeyebilir (Rouse et al., 1974). Bazı farklılıklar ortaya çıkabilir. TVI'nin hesaplanma yöntemi aşağıdaki gibidir:

$$TVI = \sqrt{[(IR - RED) / (IR + RED)]} \quad (2.10)$$

2.10.7. Yansımada modifiye edilmiş klorofil emilim indeksi (MCARI)

MCARI (Modified Chlorophyll Absorption in Reflectance), klorofil emiliminin derinliğini ölçen bir metrik olarak işlev görür ve yaprak alanı indeksi (LAI) değişimlerinin yanı sıra klorofil konsantrasyonlarındaki değişimlere son derece hassas bir şekilde yanıt verir. Ayrıca MCARI değerleri, aydınlatma koşulları, toprak özellikleri ve diğer fotosentetik olmayan malzemelerin neden olduğu arka plan yansımalarından etkilenmemektedir (Daughtry et al., 2000).

$$(MCARI) = ((B05 - B04) - 0.2(B05 - B03)) * \left(\frac{B05}{B04}\right) \quad (2.11)$$

2.10.8. Üçgensel Klorofil indeksi (TCI)

TCI (Triangular Chlorophyll index), klorofil içeriği ile ilişkiyi geliştirerek ve doygunluk etkisini azaltarak klorofil içeriği almanın doğruluğunu iyileştirmek için formüle edilmiştir. Sentinel-2 multispektral bantlarından üretilmektedir (Hunt et al., 2011).

$$(TCI) = 1.2 * (B05 - B03) - 1.5 * (B04 - B03) * \sqrt{\left(\frac{B05}{B04}\right)} \quad (2.12)$$

2.10.9. Diğer İndeksler

Çalışmada kullanılmak üzere tarım alanlarının izlenmesi, sınıflandırma çalışmaları, yaprak alanı, toprak analizi gibi çalışmalar için üretilmiş bazı diğer indekslerin bilgileri, formülleri Tablo 2.8'te listelenmiştir (http-9).

Tablo 2.8. Temel indeksler ve formülleri

İNDEKS İSMİ	İNDEKS KISALTMASI	FORMÜL
Korelasyon İndeksi	CI	$((B5-B1))/((B5))$
Fark İndeksi	DI	$(B9-B3)$
Norm İndeks	N-NIR	$B8/(B8+B4+B3)$
Yeşil Norm İndeksi	N-G	$B3/(B8+B4+B3)$
Normalize Fark İndeksi	ND	$(B8-B12)/(B8+B12)$
Normalize Fark İndeksi(R/G)	ND(R/G)	$(B4-B3)/(B4+B3)$
Kızılötesi Bitki Örtüsü İndeksi	IPVI	$(B8/((B8+B4)/2))(NDVI+1)$
Yoğunluk İndeksi		$(B4+B3+B2)/30.5$
Spesifik Yaprak Alanı İndeksi	SLA	$B8/(B4+B12)$
Klorofil İndeksi		$B8/B3-1$
Mavi Geniş Dinamik Aralık İndeksi		$(0,1*B8-B2)/(0,1*B8+B2)$
Pan Ndvı		$(B8-(B4+B3+B2))/(B8+(B4+B3+B2))$
Yeşil Yaprak İndeksi	GLI	$(2*B3-B4+B2)/(2*B3+B4+B2)$
Klorofil Bitkiörtüsü İndeksi		$B8 \ B4/ \ [B3] \ ^2$
Su İndeksi	WI	$B8A/B9$
Normalize Fark Kızılötesi İndeksi	NDII	$((B8A-B11))/((B8A+B11))$
B7 Bantlı Yeşil Klorofil İndeksi		$(B07/B03)-1$
Optimize Edilmiş Toprak Ayarlı Bitki Örtüsü İndeksi	OSAVI	$1,16*((B7-B4))/((B7 + B4 + 0.16))$
Kanopi Klorofil İçerik İndeksi	CCCI	$((B7-B5)/(B7+ B5))/((B7-B4)/(B7+ B4))$
Yeşil Biyokütle İndeksi 2	GBM	$(B05-B03)/(B05+ B03)$
Trans Klorofil Emilim Oranı İndeksi	TCARI	$3*[(B05-B04)-0.2*(B05-B03)*(B05/B04)]$
Yeşil Bitki Örtüsü İndeksi	VIG	$(B03-B04)/(B03+ B04)$
Yeşil-Kırmızı Normalleştirilmiş Fark İndeksi	GRND	$((B2-B3))/((B2+B3))$
Basit Oran İndeksi	SR	$B4/B3$
Atmosfere Dayanıklı Bitki Örtüsü İndeksi	ARVI	$(B4-(2*B3-B1))/(B4+(2*B3-B1))$
Yeşil Normalleştirilmiş Fark Bitki Örtüsü İndeksi	GNDVI	$((B4-B2))/((B4+B2))$
Geniş Dinamik Aralık Bitki Örtüsü İndeksi	WDRVI	$((0.1*B4-B3))/((0.1*B4+B3))$

2.11. Sınıflandırma

Bir veri kümesi içerisinde farklı kategorilere ait nesneleri tanımlayarak, bu nesneleri benzerliklerine göre gruplandırma işlemi olarak adlandırılan sınıflandırma, nesnelerin özelliklerine dayalı bir tür gruplandırma işlemidir. Otomatik sınıflandırma, veri kümesinde bulunan nesneleri homojen sınıflara bölmek veya belirli sayıda sınıfi

tanımlamak için matematik ve istatistiksel yöntemler kullanılarak gerçekleştirilen bir işlem olarak tanımlanır.

Sınıflandırma, genellikle farklı bilim dallarının bir araya gelmesi ile alınan bir kararın sonucudur. Özellikle görüntü sınıflandırması, bir görüntüdeki her pikseli sınıflara veya temalara otomatik olarak atama amacını taşır. Bu, görüntüdeki nesnelerin kontrol edilmiş (kullanıcı tarafından tanımlanan) veya kontrolsüz (program tarafından tanımlanan) sınıflara ayrılmasıyla gerçekleştirilir. Bu tür sınıflandırmalar özellikle uydu görüntülerinin arazi kullanım durumlarını belirlemek için kullanılır. Sınıflandırma sonuçları, vektör verilere dönüştürülerek tematik haritalar oluşturulur. Bu süreçte, sınıflandırmanın doğruluğu ve görüntü çözünürlüğü, sonuçların kullanım ölçeklerini belirlemek açısından önemlidir.

Görüntü, yeryüzündeki nesnelerin yansıttığı veya yaydığı ışığın algılayıcı tarafından yakalanmasıyla oluşur. Bu nedenle, farklı spektral bantlardaki veriler nesneleri ayırt etmede önemli bir rol oynar. Nesneler, elektromanyetik spektrumun farklı bölgelerinde farklı yansımalar yapar, bu da birden fazla bantın kullanılmasıyla nesnelerin sınıflandırılmasını kolaylaştırır. Örneğin, iki nesnenin elektromanyetik spektrumun yakın aralıklarındaki bir bölgede benzer yansımalar yaptığını düşünelim. Bu nesneleri ayırt etmek zordur, ancak farklı bantlar kullanıldığında bu sorun çözülebilir.

Bazı uygulamalarda aynı bölgenin farklı zamanlarda çekilen görüntüleri kullanılarak alanın değişimini incelemek mümkündür. Örneğin, Ankara'da farklı zamanlarda çekilen görüntülerle yeşil alanın değişimini incelemek istediğinizi varsayalım; bu durumda, her iki görüntüdeki yeşil alanın ayrı ayrı sınıflandırılması ve sonuçların karşılaştırılması gerekmektedir.

Uzaktan algılama ile elde edilen görüntüler, yeryüzüne ait farklı türde bilgi içerir. Bu bilgiler, elektromanyetik spektrumun farklı bölgelerindeki enerjinin ölçüldüğü ve bantlara kaydedildiği verilerden elde edilir. Bant verileri genellikle hamdır ve bilgi çıkarmak için farklı analiz ve yorumlama teknikleri kullanılmalıdır.

Nesnelerin farklı yansıma değerlerine sahip olmaları, aynı nesnelerin farklı sınıflandırmalara tabi tutulmasına neden olabilir. Bu nedenle, uzaktan algılama verileri içindeki spektral sınıfları tanımlayan istatistiksel yöntemler kullanılarak bu değerler gruplandırılır. Görüntü sınıflandırma kurallarının temel amacı, her pikseli alanın konusuna ve sınıfına göre ayırmaktır. Bu genellikle çoklu bantlı görüntülerin kullanılmasıyla gerçekleştirilir.

Sınıflandırma işlemi sırasında dikkat edilmesi gereken bazı önemli hususlar vardır:

- Algılayıcının, algılama zamanının ve spektral bantların hedefe uygun şekilde seçilmesi
- Bantlardan hedefe yönelik doğru indekslerin hesaplanması
- Yeryüzü özelliklerini belirlemek için kontrol alanlarının tanımlanması
- Hedefe yönelik sınıflandırma algoritmalarının seçilmesi
- Belirlenen özelliklerin tüm görüntüye uygulanması
- Sonuç görüntülerin doğruluk analizlerinin yapılması

Sınıflandırma sonuçları, iki tür hata içerebilir:

- Piksellerin yanlış bir sınıfa atanması
- Piksellerin hiçbir sınıfa atanamaması

Bu nedenle, sınıflandırma işlemi öncesi en uygun bant kombinasyonunun seçilmesi ve hata olasılığını en aza indiren sınıflandırma yönteminin belirlenmesi önemlidir.

Sınıflandırma işlemi piksel tabanlı ve nesne tabanlı sınıflandırma olmak üzere iki temel gruba ayrılmaktadır.

2.11.1. Piksel tabanlı sınıflandırma

Piksel tabanlı sınıflandırma yöntemi yaygın olarak kontrollü ve kontrolsüz sınıflandırma yöntemleri olmak üzere ikiye ayrılmaktadır.

2.11.1.1. Kontrolsüz sınıflandırma

Bu yöntem, kullanıcı müdahalesine gerek kalmadan otomatik olarak nesneleri gruplandırma esasına dayanır. Kontrolsüz sınıflandırma işlemi için sıklıkla kullanılan bir yöntem "Tekrarlayan Veri Analizi Yöntemi" ISODATA (Iterative Self Organizing Data Analysis Technique) olarak bilinir. Bu yöntem, sınıflandırmayı tekrar tekrar gerçekleştirme ve her iterasyon sonrasında istatistiksel hesaplamalar yapma ilkesine dayanır.

Bu yöntem, minimum uzaklık karar kuralını kullanır. Görüntüdeki pikseller, genellikle sol üst köşeden başlayarak sırasıyla soldan sağa ve satır satır analiz edilir. Her pikselin her bir sınıfın ortalaması ile olan spektral uzaklığı hesaplanır ve en yakın sınıfa atanır. İlk başta istenen sınıf sayısı kadar kümeler oluşturulur ve bu kümelerin

ortalamları hesaplanır. İlk iterasyonun ardından, her kümenin yeni ortalamları hesaplanır ve bu yeni ortalamlar bir sonraki iterasyonda kullanılır.

Kontrolsüz sınıflandırma, görüntü verilerinin tanımlanamadığı durumlarda başvurulacak bir yöntemdir. Bu yöntem, arazi örtüsünün türünün bilinmesini gerektirmez, ancak öncelikle sınıf sayısı belirlenir. Ayrıca, veri bantı değerleri kullanılarak benzer pikseller otomatik olarak tespit edilir. Bu belirlenen piksellere semboller, değerler veya etiketler atanır ve benzer özelliklere sahip sınıflar gerektiğinde birleştirilir.

Kontrolsüz segmentasyon sonucu elde edilen sınıflar, spektral sınıflardır ve bu sınıfların özellikleri başlangıçta bilinmez. Kullanıcı, sınıflandırılmış görüntüyü inceleyerek spektral sınıfların değer bilgilerini tespit etmek için farklı referans bilgileriyle (harita, görüntü vb.) karşılaştırma yapar. Doğal spektral sınıflar, veriler içindeki dağılım diyagramları yardımıyla tespit edilebilir.

2.11.1.2. Kontrollü sınıflandırma

Denetimli sınıflandırma, uzaktan algılama görüntü verilerinin niceliksel analizi için en sık kullanılan prosedürdür. Bir görüntüdeki pikselleri belirli yer örtüsü türlerini veya sınıflarını temsil edecek şekilde etiketlemek için uygun algoritmaların kullanılmasına dayanır. Bunun için, ilgilenilen sınıflar için olasılık dağılım modellerine dayalı olanlardan, multispektral alanın en uygun şekilde konumlandırılmış yüzeyler kullanılarak sınıfa özgü bölgelere bölündüğü algoritmalar kadar değişen çeşitli algoritmalar mevcuttur. Seçilen yönteme bakılmaksızın, temel pratik adımlar şunlardır:

- Görüntünün bölümlere ayrılacağı zemin örtüsünün türlerine karar verilir. Örneğin su, kentsel bölgeler, ekili alanlar, meralar vb. olabilir.
- İstedığınız sınıf kümesinin her birinden temsili veya prototip pikselleri seçin. Bu piksellerin eğitim verilerini oluşturduğu söylenir. Her sınıf için eğitim setleri, saha ziyaretleri, haritalar, hava fotoğrafları ve hatta görüntü verilerinden (basılı formda veya bir görüntü analiz sisteminin renkli ekranında) oluşturulan renkli kompozit ürünün fotoğrafla yorumlanması kullanılarak oluşturulabilir. Genellikle belirli bir sınıfa ait eğitim pikselleri, bir sınırla çevrelenmiş ortak bir bölgede yer alır. Bu bölgeye genellikle eğitim alanı denir.
- Kullanılan belirli sınıflandırıcı algoritmanın parametrelerini tahmin etmek için eğitim verileri kullanılmaktadır. Bu parametreler, kullanılan olasılık modelinin özellikleri olmakta veya multispektral uzaydaki bölümleri tanımlayan denklemler

olmaktadır. Belirli bir sınıfa ait parametreler kümesine bazen o sınıfın imzası da denir.

- Eğitimli sınıflandırıcıyı kullanarak görüntüdeki her pikseli istenen yer örtüsü türlerinden (bilgi sınıfları) birine etiketlenir veya sınıflandırılır. Burada ilgilenilen görüntü bölümünün tamamı tipik olarak sınıflandırılır. Adım 2'deki eğitim, kullanıcının görüntü piksellerinin belki de %1'ini başka yollarla tanımlamasını gerektirmiş olsa da bilgisayar geri kalanını sınıflandırma yoluyla etiketlemektedir.
- Sınıflandırmanın sonuçlarını özetleyen tablo özetleri veya tematik (sınıf) haritalar üretilir.

Kontrollü sınıflandırmanın alt başlığı olarak ele alınan bazı farklı güncel yöntemler aşağıda verilmektedir.

2.11.2. Nesne tabanlı sınıflandırma

Uzaktan algılama görüntüleri kullanılarak, nesnelerin otomatik olarak tespit edilmesi ve sınıflandırılması, uzaktan algılama biliminin önemli bir araştırma alanını oluşturmaktadır. Bu tür görüntülerin analizi, genellikle görüntü sınıflaması olarak adlandırılan bir yöntemle gerçekleştirilir. Bu yöntem, görüntüdeki her pikselin yansıma ve parlaklık değerlerini kullanarak kullanıcı tarafından tanımlanan sınıflara atanmasını içerir.

Sınıflandırma işlemi genellikle piksel tabanlı ve nesne tabanlı yöntemlerle gerçekleştirilir. Son yıllarda, geleneksel piksel tabanlı sınıflandırma yerine nesne tabanlı sınıflandırmanın daha fazla tercih edilmeye başlamasının temel nedeni, uydu görüntüleri ve hava fotoğraflarının mekânsal çözünürlüğünün artması ve piksel tabanlı yaklaşımın bu zengin bilgiyi tam olarak yansıtamamasıdır (Navulur, 2006). Ayrıca, piksel tabanlı sınıflandırmalar sadece pikselin gri değerlerine dayanırken, nesne tabanlı sınıflandırmalarda doku, şekil, büyüklük ve spektral bilgilerini de kullanmaktadır (Sabuncu, 2016).

Nesne tabanlı sınıflandırma, görüntüde benzer spektral özelliklere sahip piksellerin bir araya getirilerek bu pikselleri temsil eden nesnelerin oluşturulması ve piksellerin yerine bu nesnelerin sınıflandırılmasına dayanmaktadır (Blaschke, 2010; Myint, 2011). Bu yöntem sayesinde yüzlerce piksel yerine bu piksellerden oluşan nesneler sınıflandırılmaktadır. Doku, yapı, nesne büyüklükleri ve spektral bilgiler, sınıflandırma

sürecinde dikkate alınarak nesnelerden elde edilmektedir (Sabuncu, Uca Avcı, et al., 2016).

Nesne tabanlı sınıflandırma işleminde bilinmesi ve her proje için ayrı oluşturulması gereken aşama segmentasyon aşamasıdır. Bu aşama, benzer spektral özelliklere sahip piksellerin bir araya getirilmesi ve raster görüntüden nesnelerinin oluşturulmasını sağlamaktadır. Segmentasyonun temel amacı, görüntünün farklı bölgelere ayrılması ve anlamlı nesnelerin otomatik olarak tanımlanabilmesidir. Aynı zamanda, belirli nesnelerin görüntüden otomatik olarak çıkarılabilmesi de hedeflenir(Sabuncu A., 2016).

Nesne tabanlı sınıflandırma işlemi piksellerden oluşan raster verinin içerdiği nesnelerin doğru bir şekilde sınıflandırılmasının yanı sıra dinamik vektörel verilerin kontrolü içinde kullanılmaktadır. Buna örnek olarak şehirde ve kırsalda yapılan kaçak yapıların tespiti verilebilir.

Ayrıca nesne tabanlı sınıflandırma işlemini yapmak için kullanılan nesne sınırları mevcut olabilmektedir. Bu durumda mevcut nesne sınırlarının kontrolü segmentasyon ve sınıflandırma adımları -başlangıçta nesnelerin vektörel bilgisi yokmuş gibi- gerçekleştirilerek mevcudun kontrolü sağlanabilir. Kontrol işleminden sonra veya ihtiyaç duyulmaz ise kontrol edilmeksizin mevcut vektörel verinin doğrudan kullanılması da mümkündür. Bu durumda segmentasyon işlemi yapılmış seksenlerden vektörel veri üretilmiş gibi bu adım atlanır ve doğrudan sınıflandırma adımına geçilir.

Bu durumlara örnek olarak arazi çalışmalarıyla veya uzaktan algılama yöntemleriyle sık sık güncellenen dinamik yol, yapı-bina, kadastro parselleri, tarım parselleri vb. veriler verilebilir. Bu çalışmada da kadastro ve tarım parsel bilgileri altlık olarak kullanılmıştır.

2.11.3. Sınıflandırma algoritmaları

Uzaktan algılama, uydular ve hava platformları dahil olmak üzere çeşitli sensörler kullanarak veri toplama ve gezegenimizi uzaktan izleme yeteneğine dayanır. Uzaktan algılamanın temel tekniklerinden biri sınıflandırmadır, pikselleri veya görüntü nesnelerini spektral, uzaysal ve zamansal özelliklerine dayalı olarak farklı sınıflara ayırmak işlemidir. Bu sınıflar genelde uzaktan algılama yöntemleri ile dünya yüzeyindeki sınıflandırmaya işlemleri için; ormanlar, su kütleleri, şehir alanları, tarım alanları gibi farklı arazi örtü türlerini temsil eder.

Elde edilen bilgilerin güvenilirliği, bir dizi faktöre bağlıdır ve sınıflandırma doğruluğu ile sıkı bir ilişki içerisinde. Bu sınıflandırma doğruluğu; eğitim ve test verilerinin dağılımı, kullanılan bantların spektral ve mekânsal çözünürlüğü, sınıflandırma algoritmasının özgün özellikleri gibi birçok önemli parametreye dayanmaktadır. Genellikle "bilgi çıkartma" olarak adlandırılan görüntü sınıflandırma, görsel verileri anlamlı arazi örtüsü bilgisine dönüştürme işlemini ifade eder. Bu dönüşüm sürecinde, genellikle uydu görüntülerinin sınıflandırılmasında sıkça kullanılan makine öğrenme algoritmaları devreye girer.

Görüntü sınıflandırma işlemi bu çalışmada olduğu gibi büyük ölçekli sınıflandırma çalışmaları ile sınırlı olmayıp gerçek ölçekli bir restorasyon işleminde veya mikro ölçekli bir biyokimya, genetik veya tıp alanında da kullanılmaktadır. Farklı amaçlar için üretilen algoritmalar genelde görüntü sınıflandırmanın her alanında kullanılabilir.

Uydu görüntülerinin sınıflandırmasında kullanılan; Maksimum Olabilirlik (Maximum Likelihood), Destek Vektör Makineleri (Support Vector Machines- SVM), Karar Ağaçları (Decision Trees), Rastgele Ormanlar (Random Forests), K-Means Kümeleme, Yapay Sinir Ağları (Artificial Neural Networks - ANN), XGBoost vb. birçok algoritma vardır. Çalışmada kullanılan dört farklı makine öğrenme algoritması detaylı incelenmiştir.

2.11.3.1. En yakın komşuluk sınıflandırma algoritması

Bu algoritmada, gözlem birimlerini birbirine olan yakınlıkları üzerinden tahmin etmeye dayanmaktadır. Tüm makine öğrenimi algoritmalarının en temel ve eskilerinden birisi olarak bilinmektedir. Temel fikir, bir nesnenin sınıflandırılması için çoğunluk oyuyla en yakın komşularının kullanılmasıdır. Bir nesne, en çok ortak özelliklere sahip olan sınıfa atanır. Aynı zamanda, birden fazla yakın komşunun oyları toplanarak sınıflandırma yapmak da mümkündür. Örneğin, eğer $k = 1$ ise, nesne en yakın komşusunun sınıfına atanır. Ancak, eğer $k = 5$ ise, en yakın 5 komşunun sınıfı dikkate alınarak sınıflandırma yapılır. Burada K , sınıflandırılmamış bir nesnenin piksel komşuluklarındaki örnek sayısını belirtir. Hangi K 'nin en uygun olduğu, verilere bağlı olarak değişebilir (B. Ripley et al., 2015; B. D. Ripley, 1996; Venables & Ripley, 2002)

2.11.3.2. Rastgele orman algoritması

Sınıflandırma yöntemi, birçok toplu öğrenme yöntemine kıyasla hem hız hem de yüksek doğruluk sağlama konusunda belirli avantajlar sunmaktadır. Rastgele orman sınıflandırıcısı, kullanıcı tarafından tanımlanan iki önemli parametre kullanarak bir ağaç oluşturur. Bu parametreler, her düğümde kullanılan değişken sayısı (m) ve oluşturulan ağaçların sayısı (N) ile ilgilidir. Bu parametreler, genellikle çalışma alanı ve sınıflandırılan nesnelerin özelliklerine bağlı olarak deneme yanılma yoluyla belirlenir.

Bu sınıflandırma yöntemi temel olarak dört adımlı bir çalışma prensibine dayanır. İlk adımda, belirli bir veri kümesinden rastgele örnekler seçilir. Ardından, her örnek için bir karar ağacı oluşturulur ve her ağaçtan tahmin sonuçları elde edilir. Bu tahmin sonuçları daha sonra oy kullanılarak toplanır. Nihai tahmin sonucu, en çok oy alan tahmin sonucu olarak seçilir.

Sınıflandırma yönteminde tercihen özellik seçimi için boruta algoritmasını kullanır. Bu algoritma istatistiksel olarak daha az ilgili olduğu kanıtlanmış değişkenleri yinelemeli olarak elemek için kullanılır, bu da tahmin performansını artırır. Boruta, değişken önem ölçüsü çıktısı veren herhangi bir sınıflandırma yöntemiyle çalışabilen bir özellik seçim algoritmasıdır(Kursa & Witold, 2010).


Rastgele Orman modelinin en önemli parametrelerinden ikisi ağaç sayısı (n_{tree}) ve m_{try} sayısıdır. Ağaç sayısı (n_{tree}) parametresi, birleştirilen temel modellerin veya karar ağaçlarının sayısını belirler ve son tahmini oluşturmak için kullanılır. Genellikle 50 ile 500 arasında bir değer seçilir. Bu değeri seçerken, ağaç sayısının azaltılması tahmin performansını düşüreceği ve arttırılmasıyla tahmin süresinin artacağı göz önüne alınır, bu nedenle projenin gereksinimlerine göre deneme yanılma yoluyla belirlenmelidir.

Modelde “ m_{try} ”, ağaçların oluşturulurken dikkate alınan özellik sayısını ifade etmektedir. En az bir özellik kullanılması gereklidir ve bu sayı arttıkça seçilen özelliklerin çeşitliliği artar, ancak bununla birlikte rastgelelikte artmaktadır. m_{try} sayısının azaltılması özellikleri göz ardı eder ve daha sabit sonuçlar üretilmesine sebep olmaktadır. Bu nedenle m_{try} değerinin genellikle toplam özellik sayısının üçte biri olarak seçilmesi önerilir (Breiman, 2001).

2.11.3.3. Destek vektör makinaları sınıflandırma yöntemi


Destek Vektör Makineleri (DVM), genellikle sınıflandırma problemlerini çözmek için kullanılan gözetimli öğrenme yöntemlerinden biridir. Bu yöntem, bir düzlem üzerine yerleştirilmiş noktaları ayırmak için bir doğru çizer. İki farklı sınıfa ait noktaların bu doğruya olan uzaklığını maksimum yapmayı hedefler.

Özellikle karmaşık, ancak küçük ve orta ölçekli veri setleri için uygundur. Bir sınıflandırma problemiyle karşı karşıya olduğumuzda, temel amaç gelecekteki verileri hangi sınıfa dahil edilebileceğine karar vermek ve bu işlemi yaparken iki sınıf arasında bir ayırıcı çizmek gereklidir. İşte bu noktada Destek Vektör Makineleri devreye girer ve bu ayırıcı doğru ± 1 arasındaki yeşil bölgeye "Margin" adını verir (Şekil 2.13). Margin, iki veya daha fazla sınıfı ne kadar iyi ayrıldığının göstergesidir.



Şekil 2.13. DVM algoritma prensibi

Ancak Margin her zaman aynı genişlikte olmayabilir. Örnekler bazen Margin bölgesine girebilir ve bu duruma "Soft Margin" denir. Özellikle veriler doğrusal olarak ayrılabiliriyorsa "Hard Margin" kullanılabilir, ancak bu durum aykırı değerlere duyarlıdır. Bu nedenle, bazen Hard Margin bazı durumlarda ise Soft Margin tercih edilebilir. Bu iki yaklaşım arasındaki dengeyi sağlamak için SVM içinde bulunan C hiperparametresi kullanılır. C ne kadar büyükse, Margin o kadar dar olur ve modelin aşırı uyuma (overfitting) eğilimi artar. Ayrıca, modelin aşırı uyumasını engellemek için C değerini azaltabiliriz (Chih et al., 2003).



Şekil 2.14. DVM iki sınıfın ayrımı

Cost: İki sınıfa ait destek vektörler arasındaki çizgi veya şeritin boyutunu belirleyen faktördür.

Epsilon: Değerin artırılması daha hızlı sonuç almayı sağlar fakat küçük hataların göz ardı edilmesine yol açtığı için doğruluğu azaltabilir (Şekil 2.14).

2.11.3.4. XGBoost sınıflandırma yöntemi

Boosting, zayıf öğrencileri güçlü öğrencilere dönüştürmek için kullanılan bir yöntemdir ve bu dönüşümü aşamalı olarak iterasyonlarla gerçekleştirir. Gradient Boosting'in ilk adımında, başlangıçta bir başlangıç yaprağı (initial leaf) oluşturulur. Daha sonra tahmin hataları göz önüne alınarak yeni ağaçlar oluşturulur. Bu işlem, belirli bir sayıda ağaç oluşturulana veya model daha fazla geliştirme kaydedilemeyeceğine kadar devam eder. Bu tahmin süreci, gelecekteki adımlarda daha yakın sonuçlara ulaşmak için iterasyonlarla yakınsar, bu nedenle iterasyon sayısı herhangi bir sayı olabilir, varsayılan olarak 0,5'tir.

Bu tahminin doğruluğu, modelin hatalı tahminlerinin incelenmesiyle değerlendirilir. Hatalar, gözlemlenen değer ile tahmin edilen değer arasındaki farktır. Bir sonraki aşamada, hataları tahmin etmek için bir karar ağacı oluşturulur ve bu ağaç hataları azaltarak daha doğru tahminlere ulaşmayı amaçlar.

Oluşturulan ağaçların her bir dalı için benzerlik skoru hesaplanır, bu skor, verilerin dallarda ne kadar iyi gruplandığını gösterir. Hangi ağacın daha iyi olduğunu belirlemek

için kazanç (gain) hesaplanır. Benzerlik skoru ile dalların değerlendirilmesi sırasında, kazanç ile tüm ağaçların değerlendirilmesi sırasında kullanılır.

Hangi ağacın daha yüksek kazanç değerine sahip olduğuna karar verildikten sonra budama (prune) işlemi başlar. Budama için "gamma" adı verilen bir değer seçilir ve bu değer, kazanç skoruna bir eşik getirir. Kazanç skoru, gamma skorundan düşük olan dallar budanır. Bu nedenle gamma değeri artırıldığında, sadece değerli dallar ağaçta kalır ve aşırı öğrenme önlenir. Budama işlemi en alttaki daldan başlayarak yukarı doğru ilerler. Eğer en alt düzeydeki dal budanmamışsa, üstündeki dallar için ek bir inceleme yapılmasına gerek yoktur.

Varsayılan gamma değeri 0'dır ve bu, kazanç skorunun negatif olduğu durumlarda dalların budanacağını gösterir. Eğer dallar tamamen budanmışsa, başlangıçta yapılan tahmin 0,5 olarak kalır.

Ayrıca, Lambda değeri de önemlidir. Lambda arttıkça hesaplanan benzerlik skoru ve kazanç skoru düşer. Bu da öğrenmenin zorlaştığını ancak aşırı öğrenmenin azaldığını gösterir. Lambda, formüldeki konumuna bağlı olarak dalları etkiler ve bu nedenle lambda, daha fazla değere sahip olan dalları daha az etkiler. Yani, lambda, daha fazla değeri olan dalların korunmasına yardımcı olur ve aşırı öğrenmeyi engeller (Tianqi Chen ve Carlos Guestrin, 2016).

Sınıflandırmada ağaç sayısını ve sınıflandırma doğruluğunu etkilen bazı değişkenler şunlardır;

- **Eta:** öğrenme oranını kontrol etmektedir. Mevcut yaklaşıma eklendiğinde her ağacın katkısını $0 < \eta < 1$ faktörüyle ölçeklendirilir. Aşırı uyumu önlemek için kullanılır. Eta için daha düşük değer, döngüler için daha büyük değer anlamına gelir; düşük eta değeri, modelin aşırı uydurmaya karşı daha dayanıklı ancak hesaplaması daha yavaş olduğu anlamına gelir. Varsayılan: 0,3
- **Gamma:** Ağacın yaprak düğümünde daha fazla bölüm oluşturmak için gereken minimum kayıp azaltımı
- **max_third:** bir ağacın maksimum derinliği. Varsayılan: 6
- **min_child_weight:** İhtiyaç duyulan minimum örnek ağırlığı toplamı (hessian). Ağaç bölümleme adımı, örnek ağırlığının toplamı
- **min_child_weight:** Düşük olan bir yaprak düğümle sonuçlanırsa, oluşturma süreci daha fazla bölümlendirmeden vazgeçmektedir. Bu, doğrusal regresyon

modunda her düğümde olması gereken minimum örnek sayısına karşılık gelir. Varsayılan: 1

- **Subsample:** Eğitim örneğinin alt örnek oranı. Bunu 0,5'e ayarlamak, XGBoost'un ağaçları büyütmek için veri örneklerinin yarısını rastgele topladığı anlamına gelir ve bu, aşırı uyumu önlemektedir. Hesaplamayı kısaltır (çünkü analiz edilen daha az veri vardır). Bu parametrenin eta ile kullanılması ve döngülerin arttırılması tavsiye edilir. Varsayılan: 1
- **colsample_bytree:** Ağaç oluştururken sütunların alt örnek oranı. Varsayılan: 1
- **lambda L2:** ağırlıklara ilişkin düzenleme terimi. Varsayılan: 1
- **alfa L1:** ağırlıklara ilişkin düzenleme terimi. (birincil derece önemli olmadığı için L1 düzenlemesi yoktur). Varsayılan: 0
- **num_parallel_tree:** Deneysel parametre. Tur başına büyüyen ağaç sayısı. Rastgele Ormanı XGBoost aracılığıyla test etmek için kullanışlıdır (colsample_bytree < 1, subsample < 1 ve round = 1). Varsayılan: 1
- **monotone_constraints:** Sayısal bir vektör 1, 0 ve -1'den oluşur ve uzunluğu eğitim verisindeki özellik sayısına eşittir. 1 artıyor, -1 azalıyor ve 0 kısıtlama yok.
- **interaction_constraints:** İzin verilen etkileşimlerin özellik endekslerini belirten vektörlerin listesi. Listenin her ögesi, belirtilen özelliklerin birbirleriyle etkileşime girmesine izin verilen bir etkileşimi temsil eder. Özellik dizini değerleri 0'dan başlamalıdır (0, ilk sütuna atıfta bulunur). Etkileşim kısıtlaması olmaması için bağımsız değişkeni belirtilmemiştir (Chen & Guestrin, 2016).

2.11.4. Doğruluk analizi

Sınıflandırma algoritmaları kullanılarak yapılan sınıflandırma her zaman mükemmel sonuç vermez. Bu nedenle sınıflandırılmış görüntü, kümelerin etiketlenmesi, eğitim alanlarının yanlış etiketleme ile hazırlanması, ayırt edilemeyen sınıflar ve bantlar arasındaki korelasyon, kusurlu sınıflandırma algoritması vb. nedenlerden dolayı birçok hata içermektedir. Sınıflandırılmış bir görüntünün doğruluk değerlendirmesi, uzaktan algılanan verilerden elde edilen bilgilerin kalitesini verir. Doğruluk değerlendirmesi, uzaktan algılanan verilerden üretilen bir haritanın, başka bir kaynaktan elde edilen bir harita ile karşılaştırılması yoluyla gerçekleştirilir.

2.11.4.1. Hata matrisi

Sınıflandırma doğruluğunu ifade etmenin en yaygın yollarından biri, bir sınıflandırma hata matrisinin (karışıklık matrisi veya beklenmedik durum tablosu) hazırlanmasıdır. Bu konuda pek çok matematiksel yaklaşım bulunmaktadır. Genel olarak her arazi kullanımı arazi örtüsü sınıfından en az 50 numunenin dahil edilmesi önerilmektedir. Çalışma alanı büyükse numune sayısı artırılmalıdır. Hata matrisini oluşturmak ve sınıflandırma modellerinin etkinliğini ölçmek için değişkenin tahmin edilen ve gerçek değerlerinin karşılaştırılması gerekmektedir. Sınıflandırma tahminleri genellikle Tablo 2.9’da olduğu gibi dört temel değerlendirmeden birine sahiptir, bunlar:

Tablo 2.9. Sınıflandırma tahminlerinin değerlendirilmesi

No	Soru	Cevap
1	Doğruya doğru demek (True Positive – TP)	DOĞRU
2	Yanlış a yanlış demek (True Negative – TN)	DOĞRU
3	Doğruya yanlış demek (False Positive – FP)	YANLIŞ
4	Yanlış a doğru demek (False Negative – FN)	YANLIŞ

Bu yöntemde oluşturulan tablo, üretici doğruluğu, kullanıcı doğruluğu, genel doğruluk ve kappa istatistiğinden elde edilen değerleri içerir (Anand, 2017).

Genel doğruluk: Genel sınıflandırma doğruluğunu temsil eder. Doğru şekilde sınıflandırılmış piksellerin toplam sayısının, referans piksellerin toplam sayısına bölünmesiyle hesaplanır. Bu ölçüm, bize her bir sınıfın ayrı ayrı ne kadar iyi olduğu hakkında bilgi vermez. Üretici ve kullanıcı doğruluğu, sınıf doğruluğunu ölçmek için yaygın olarak kullanılan iki ölçüdür.

Üretici doğruluğu: Belirli bir özelliğin doğru bir şekilde sınıflandırılma olasılığını ifade eder. Her kategori için doğru bir şekilde sınıflandırılmış piksellerin, o kategori için seçilen örnek piksellerin sayısına bölünmesiyle hesaplanır.

Kullanıcı doğruluğu: Haritada belirli bir sınıf olarak etiketlenen bir pikselin gerçekten bu sınıfa ait olma olasılığını ifade eder. Doğru bir şekilde sınıflandırılmış piksellerin, o kategoriye ait olarak sınıflandırılan toplam piksellerin sayısına bölünmesiyle hesaplanır. Üretici doğruluğu ve kullanıcı doğruluğu genellikle farklıdır. Örneğin, su için üretici doğruluk %95 iken kullanıcı doğruluğu %87 olabilir.

2.11.4.2. Kappa istatistiği

Doğruluk analizinde kullanılan ayırık, çok değişkenli bir yöntemdir. Sınıflandırma sürecinde piksellerin/parsellerin rastgele olarak sınıflara atanması yüzdesel olarak doğru bir değer üretmektedir. Açıkçası, görüntü sınıflandırması sırasında pikseller/parseller rastgele atanmaz, ancak bir sınıflandırmanın doğruluğunu değerlendirirken rastgele şansın katkısını hesaba katmaya çalışan istatistiksel ölçümler vardır. Ortaya çıkan Kappa ölçüsü, sınıflandırmadaki şans uyumunu telafi eder ve piksellerin doğru kategorilere rastgele atanma olasılığıyla karşılaştırıldığında sınıflandırmanın ne kadar iyi performans gösterdiğinin bir ölçüsünü sağlar (Anand, 2017).

$$Kappa = \frac{(n * \sum_{i=1}^K a_{ii}) - \sum_{i=1}^K (a_{i+} \times a_{+i})}{n^2 - \sum_{i=1}^K (a_{i+} \times a_{+i})} \quad (2.13)$$

K = Sınıflandırmadaki sınıf sayısı

n = Sınıflandırmadaki toplam piksel sayısı

a_{ii} = Hata matrisin ana diyagonal elementi


a_{i+}, a_{+i} = Her satır ve sütun toplamından üretilen değerler

3. MATERİYAL YÖNTEM

Bu bölümde çalışmada uygulanan iş akışı, çalışmada kullanılan raster, vektör materyallerden üretilen veri setlerinin özellikleri, görüntü keskinleştirme kullanılan yöntemler, sınıflandırmada kullanılacak bantlar ve indeksler hakkında bilgiler verilmiştir.

3.1. Uygulama İş Akışı

Tez çalışması kapsamında uygulanan işlemlere ait iş akışı Şekil 3.1’de gösterilmiştir. Çalışmada öncelikle Tarım Orman Bakanlığı Çiftçi Kayıt Sisteminden elde edilen parsel sınırları ile çalışma sahası için temin edilen uydu görüntüleri kullanılarak parsel sınırlarının analize uygun hale getirilmesi aşaması gerçekleştirilmiştir.



Şekil 3.1. Tez çalışması kapsamında uygulana iş akışı şeması

İkinci olarak Sentinel-2 ve PlanetScope görüntülerinin füzyon işlemi ile Pan-keskinleştirilmiş görüntü bantları üretilmiştir. Araştırmanın üçüncü aşamasında analiz aşamasında kullanılacak Sentinel-2, Planet Scope ve Pan-keskinleştirilmiş görüntülerden bitki indeksleri hesaplaması gerçekleştirilmiştir. Dördüncü aşamada düzeltilen parsel sınırları ile üretilen bitki indeksleri ve görüntü bantları kullanılarak her bir uydu görüntüsü için tarım parselleri kullanılarak eğitim ve test veri setleri üretilmiştir. Araştırmanın beşinci aşamasında eğitim verileri kullanılarak araştırma kapsamında ele alınan Rastgele Orman, Destek Vektör Makineleri, K-En Yakın Komşuluk ve XGBoost makine öğrenme algoritmaları için tarım parseli sınıflandırma modelleri geliştirilmiştir. Son aşamada ise geliştirilen modeller test veri setine uygulanarak geliştirilen modellerin başarıları test edilmiştir. Tez çalışmasının 3.2 Veri setlerinin hazırlanması bölümünde, tarım parselleri ve uydu görüntülerinin özellikleri ile iş akışının ilk dört aşaması detaylı olarak anlatılmıştır. Model geliştirme ve doğrulama aşamaları tez metninin dördüncü bölümünde detaylı olarak ele alınmıştır.


3.2. Veri Setlerinin Hazırlanması

Çalışma kapsamında kullanılan veri setinin altlığını tarım parsellerine ait vektör veriler ve analizlerde kullanılan uydu görüntüleri oluşturmaktadır. Verilerin temini, gerekli düzeltmelerin yapılması, hatalı verilerin ayıklanması, farklı kaynaklardan temin edilen verilerin belirli formata getirilmesi ve analiz süreçleri veri tabanının oluşturulması için farklı süreçler izlenmiştir. Veri setinin oluşturulması ve görüntü işleme süreçlerinde; ARCGIS 10.5 yazılımı başta olmak üzere QGIS 3.26.2, ESA SNAP, ERDAS Image 2014 ücretli veya açık kaynak kodlu yazılımları kullanılmıştır. Veri işleme, makine öğrenme, görüntü keskinleştirme (pansharpening) süreçlerinde; R Studio, OTB Monteverdi açık kaynak kodlu yazılımları kullanılmıştır.

3.2.1. Uydu görüntülerinin hazırlanması


Çalışma kapsamında Sentinel-2 ve Planet Scope uydularından elde edilen görüntüler kullanılmıştır. Ayrıca Google Earth yüksek çözünürlüklü uydu görüntüsü parsel sınırlarının düzenlenmesinde yardımcı veri olarak kullanılmıştır. Uygun görüntü seçimi işlemi iki aşamada gerçekleşmiştir. Öncelikle Tarım Orman Bakanlığı Çiftçi Kayıt Sisteminden temin edilen 50.000 parselde yetişen 80'in üzerinde üründen ilk 20 tanesi

parsel adetine göre seçilmiş ve diğer ürünlerin ekili olduğu parseller listeden ve veri tabanından çıkartılmıştır. 20 ürünün ekim-hasat zaman cetvelleri oluşturulmuştur (Görsel 3.1). Bu 20 ürünün hasat zamanı, parsel sayısı ve alandaki konumsal dağılımlarına bakılarak en uygun olan 5 ürün çalışma için seçilmiştir. Bunlar uygulama sürecinde ele alınan Mısır, Pamuk, Üzüm, Domates ve Zeytin'dir.



Görsel 3.1. Çalışma alanında yetiştirilen tarım ürünlerinin ekim-hasat zamanları

Seçilen yazlık tarım ürünleri için uygun görüntülerin belirlenmesinde, Haziran-Kasım ayları arasında 10-20 gün aralıklı Sentinel-2 NDVI haritaları üretilmiştir. Üretilen NDVI haritaları ile her bir ürünün spektral imzaları belirlenmiştir. Ürünlerin yüksek NDVI yansıması verdiği ve bu yansımaların birbirinden ayırt edilebildiği tarih çalışma için analiz tarihi olarak belirlenmiştir (Şekil 3.2). Bu kapsamda alana ait PlanetScope görüntüsünün de mevcut olduğu 22 Temmuz 2019 tarihli görüntüler çalışmada analiz için tercih edilmiştir.



Şekil 3.2. Yaz bitkilerinin spektral imzaları

Çalışmada gerek NDVI haritaların üretilmesinde gerekse tarım parsellerinin tespit edilmesinde Sentinel-2 Seviye 2A yüzey yansıma verileri kullanılmıştır. Verilerin temin işlemi (<https://scihub.copernicus.eu/dhus/#/home>) resmi veri paylaşım sitesinden elde edilmiştir. Alana ait Planet Scope görüntüleri (<https://www.planet.com/explorer/>) web sayfasından temin edilmiştir. Ticari bir uydu filosu olan Planet Scope görüntüleri araştırma amaçlı olarak ücretsiz temin edilebilmektedir. Planet Scope görüntüsü de Sentinel-2 gibi farklı seviyelerde kullanıma hazır veriler sunmaktadır. Tez çalışması kapsamında kalibrasyonları ve geometrik düzeltmeleri yapılmış, orto-rektifiye edilmiş analitik yüzey yansıması verileri kullanılmıştır. Ayrıca çalışma sahasındaki parsellerin sınırlarının düzenlenmesi ve ürünlerin türünün doğrulanması için analiz tarihine yakın tarihli (10 Ağustos 2019) Google Earth yüksek çözünürlüklü uydu görüntüleri yardımcı veriler olarak kullanılmıştır. Bu veriler Google Earth Downloader uygulamasından ücretli temin edilmiştir.

3.2.2. Parsel verilerinin hazırlanması

Vektör olarak ana veri Tarım Orman Bakanlığı Çiftçi Kayıt Sistemi verisidir. 2019 yılına ait Gediz Havzasının aktif tarım bölgelerini kapsayan verinin içeriği; shape file (.shp) formatında poligon olarak tarım parsellerinin sınırlarını, parsellere ait tespit edilen veya beyan edilen ekilen tarım ürünlerini, ekim hasat tarihleri vb. bilgileri içeren

verilerdir. Excel formatında temin edilen öznitelik verilerinin tekrarlıları ve bozuk verileri tespit edilerek düzenlenmiş sonrasında ARCGIS 10.5 programında vektör veriler ile ilişkilendirilerek veri setine eklenmiştir. Bunun dışında ülke, il, ilçe, havza, mahalle, çalışma alanı sınırları ya ilgili kuruluşlardan temin edilmiş ya da proje içerisinde üretilmiş, veri seti formatına dönüştürülmüştür.

Temin edilen veriler çalışma alanı ile sınırlandırıldıktan sonra kontrol işlemi gerçekleştirilmiştir. İşlem belirli bir sistematik içerisinde manuel gerçekleştirilmiştir. Çalışma alanı ve sınıflandırmanın yapılacağı tarih içerisinde belirlenen 5 ürünün en az bir kez ekilip hasat edilemediği tüm parseller çalışma alanından çıkarılmıştır.

Yapılan sınıflandırmaya altlık olan tarım parsellerinin hazırlanması için yapılan kontrol sürecinde gözlemlenen ve düzeltilen bazı durumlar aşağıda görsellerle açıklanmıştır. Yapılan düzeltmeler özellikle uydu görüntüsü bazlı tarım ürünlerinin tespiti ve izlenmesinde çiftçi kayıt sistemi gibi veri tabanlarının nasıl organize edilmesi gerekliliğini ortaya koymak için son derece önemlidir.

Tarım parselleri genelde kadastro parsellerinden oluşmakta olup mülkiyetin miras yoluyla bölünmesi veya aynı parselde birden fazla ürün ekerek çeşitlilik sağlanması gibi ana nedenlerden dolayı çalışma sahasında tek parselde birden çok ürünün ekildiği gözlemlenmiştir. Bu gibi durumlarda ya tüm bilgiler ÇKS verilerine işlenmiş yalnızca düzenleme gerektiriyor ya da en büyük ürün veya ürünler kayıtlara geçmiş, manuel bir düzenleme gerekirse parsel geometrisinin yeniden çizimini gerektirmektedir. Örneğin Görsel 3.2'deki 76 no'lu parsel miras yolu ile bölünmüştür. Bölünen parsellerde bir yılda birden çok ürün ekildiği bilgisi bulunmaktadır. Bu ürünlerle parseller eşleştirildiğinde mısır olarak işaretlenen bazı yerlerin üzüm, üzüm olarak işaretlenen yerlerin mısır olduğu görülmüştür. Veri tabanında bu durumun düzeltilmesi için ilgili tarihteki Google Earth yüksek çözünürlüklü görüntüleri ve analiz işleminde kullanılan uydu görüntülerinden yararlanılmıştır.



Görsel 3.2. Bir kadaströ parseli içerisinde ekili farklı ürünler

Görsel 3.2’de görüldüğü gibi mülkiyeti miras yoluyla bölünmesi ve parsellerde birden çok kaydolması ya da yanlış ürün bilgisi olması gibi sebeplerle ekili ürün bilgisi hatalı kaydedilmiş olup kırmızı daire ile gösterilen parsellerde üzüm, mısır, mısırlar üzüm olarak değiştirilmiştir.

Bazı tespit veya beyanlar hatalı olup tamamen farklı ürünler ekili veya parselde ürün ekili olmayıp boştur. Görsel 3.3'te ki Mısır ekili alanlar kayıtlara Domates olarak geçmiştir.



Görsel 3.3. Mısır ekili olan parseldeki domates kaydı

Görsel 3.4'te işaretli parselde kısmi olarak zeytin ağacı bulunmakta olmasına rağmen parselin tamamında mısır ve zeytin ürünlerinin olduğu kayıtlara geçmiştir. Beyan kısmi doğru olmasına rağmen ürünün parselin tamamını temsil etmemesinden dolayı çalışmada sınıflandırmayı bozmakta veya ürün tespitinin yapılması mümkün olmamaktadır.



Görsel 3.4. Boş tarım arazisindeki hatalı kayıtlar

Görsel 3.5’te görüldüğü gibi, kayıtlara doğru geçmesine rağmen kadastro parseli içerisinde çiftçi veya çiftçilerin tarım alanlarını gayri resmi bölmesi ve ekim dikim faaliyetlerini oluşan yeni alanlara göre yapmasından kaynaklı hatalar oluşmaktadır. Bu parsellere ait veriler ÇKS kayıtlarında aynı parselin kopyalanması ile tutulmaktadır. Görsel 3.5’te ki örnekte de hatanın giderilmesi için yüksek çözünürlüklü uydu görüntüleri ile manuel tespit yapılmış ve yeni tarım parselleri oluşturularak tespit edilen ürünler veri tabanında düzeltilmiştir.



Görsel 3.5. Doğru kayıt fakat bölünmesi gereken geometri



Görsel 3.6. Doğru kayıt çalışmada kullanılamayan sera alanı

Veri tabanı incelendiğinde beyan veya tespiti doğru olmasına rağmen uzaktan algılama yöntemleri ile sınıflandırılmayan alanlardan birisi de seralardır. Görsel 3.6'da


görüldüğü gibi doğru ürün kayıtları tutulmasına rağmen sera içindeki ürünlerin uydu görüntülerinden tespitinin mümkün olmamasından dolayı veri seti içinden çıkarılmıştır.

Sera alanları ile benzer hatalara sebep olan Görsel 3.7’de verildiği gibi içinde yapı bulunan veya doğrudan tarım ürünleri ile ilgili fabrikaların bulunduğu parseller çalışma bir tabanından çıkarılmıştır.



Görsel 3.7. Doğru kayıt çalışmada kullanılamayan zeytin fabrika alanı


Doğal afet, sınır kayması gibi faktörlerden tarım parselleri içinde kalan alanlarının tamamı tarıma elverişli olmaya bilir. Bu alanlar çalışma sahasında hassas şekilde tespit edilerek sınırları yeniden çizilmiştir (Görsel 3.8).



Görsel 3.8. Farklı nedenlerden dolayı sınırları değişen parsellerin sınırlarının düzeltilmesi


Tarım parsellerinin “an” alanları da çalışma doğruluğunu etkileyen faktörlerden birisidir. An her ne kadar iki tarla arasındaki sınır belirleyen sınır çizgisi olarak bilinse de 1-5 m genişliğinde olan çizgiden çok ekilmeyen boş toprak veya taşlık olarak bırakılan büyük bir alanı kaplamaktadır. Bu alanların çalışma içerisinde çıkartılması için alanları 10.000 m² ye kadar olan parseller 5 m 10.000 m² üstü parseller 10 m olacak şekilde tamponlar atarak parsel alanları içeri doğru 5-10 metre daraltılmıştır (Görsel 3.9). Bu

sayede parsel içerisindeki yalnızca ekili tarım alanlarını temsil eden poligonlar sınıflandırmaya dahil edilmektedir.



Görsel 3.9. Küçültülmüş tampon poligonları

Daraltma sonrası 1000 m² altındaki tarım alanları çalışmadan çıkartılmıştır (Görsel 3.10). İncelendiğinde bu alanların ekilmeyen alanlar olduğu tespit edilmiştir.



Görsel 3.10. 1000 m² altındaki tarım alanları

3.2.3. Görüntü keskinleştirme (Pan Sharpening)

Landsat, Wordview gibi pankromatik bandı olan uydu görüntüleri konvasyonel yöntemlerle düşük çözünürlüklü bantları yüksek çözünürlüklü bantları ile keskinleştirilmektedir. Tez çalışmasında tarım parsellerinde yetiştirilen ürünlerin tespiti için iki farklı uydu görüntüsünden 3 farklı veri seti oluşturulmuştur. Bu veri setleri (i) Sentinel-2 bantları ve bu bantlardan üretilen indekslerden oluşan Veri Seti 1, (ii) Planet Scope bantları ve bant indekslerinden üretilen Veri Seti 2 ve (iii) Planet Scope bantları ile keskinleştirilen Pan-keskinleştirilmiş Sentinel-2 bantları ve bant indekslerinden üretilen Veri Seti 3'tür. Bu veri setlerinden birincisi (Veri Seti 1) Sentinel 2 uydusunun 10 m ve 20 m çözünürlüklü bantlarından elde edilen veri setidir. Sentinel-2 görüntüsünün 13 adet bandından 4 tanesi 10 metre, 6 tanesi 20 metre, 3 tanesi ise 60 metredir. 60 metrelik bantlar sınıflandırma işleminde çalışmaya dahil edilmeyeceği için keskinleştirilmemiştir. 20 metre mekânsal çözünürlükteki bantları 10 metre çözünürlüğe artırmak yeniden örnekleme (resample) veya keskinleştirme (pansharpening) yöntemleri kullanılmaktadır. Çalışmada Sentinel -2 görüntüleri ile yapılan tarım parsellerinin tespiti işleminde kullanılan Veri Seti 1'i hazırlamak için birçok çalışmada kullanılmış ve başarısı kanıtlanmış bir algoritma olan Yüksek Geçirgen Filtre (High Pass Filter-HPF) metodu kullanılmıştır. Keskinleştirme işlemi ERDAS 2014 sürümündeki algoritmayı içeren araçlar üzerinden yapılmıştır. Uygulama neticesinde Sentinel-2 tüm bantları 10 m mekânsal çözünürlüklü hale getirilmiştir. Yüksek Geçirgen Filtre metodunun temel çalışma prensibi, farklı mekânsal çözümlerde o an içeren multispektral görüntü uygun pankromatik görüntüyle keskinleştirilmesi şeklindedir. Bu çalışmada Sentinel-2 uydu görüntüsü pankromatik banda sahip olmadığı için 20 m mekânsal çözünürlükteki multispektral bantlar, bant-8 pankromatik bant olarak kullanarak keskinleştirilmiştir. Sonuç olarak 10 m mekânsal çözünürlüğe sahip tüm bantları içeren multispektral Sentinel-2 bantları elde edilmiştir.

Çalışma kapsamında kullanılan Veri Seti 3 Planet Scope'un 3 m yüksek çözünürlüklü görüntü bantları ile Sentinel 2'nin 10 m ve 20 m mekânsal çözünürlüklü bantlarının keskinleştirilmesi ile elde edilen veri setidir. Aynı tarihte görüntülenen farklı özellikte sensörlere sahip iki ayrı uyduya ait görüntü güncel bir yöntemle keskinleştirilmiştir.

Bu keskinleştirme sürecinde literatürde kullanılan High Pass Modulation, Model 3, XS+P yöntemleri incelenmiştir. Sentinel-2 ve Planet Scope görüntü füzyonu az sayıda

uzaktan algılama çalışmasında kullanılması sebebi ile henüz üstünlüğü kanıtlanmamış olsa da çalışmada önceki araştırma olan (Gašparović et al., 2018)'a dayanarak XS+P varyasyonel yöntemi ile füzyon işlemi gerçekleştirilmiştir. Detaylı bilgiler (Ballester et al., 2006; Gašparović & Jogun, 2018; Z. Li et al., 2020; Sadeh et al., 2021) makalelerinde verilmektedir.

P + XS yöntemi, daha yüksek çözünürlüklü görüntünün tüm kenarlarını her bir düşük çözünürlüklü multispektral bantla hizalayarak daha yüksek çözünürlüklü görüntünün geometri bilgisini sunmaktadır. Birleştirilmiş görüntünün spektral bilgilerini elde etmek için, yöntem, farklı spektral bantlarda alınan görüntülerin ortak geometrik bilgileri paylaştığını ve daha yüksek çözünürlüklü görüntünün, yüksek çözünürlüklü multispektral bantların doğrusal bir kombinasyonu olarak yaklaşık olarak tahmin edilebileceğini varsayılmıştır (Ballester vd., 2006; He vd., 2012, Gasparović ve Jogun, 2018). Önceki araştırmaya (Gašparović ve Jogun, 2018) dayalı olarak, her bir Sentinel-2 bandı, benzer spektral özelliklere sahip yüksek çözünürlüklü bir Planet Scope bandıyla birleştirilmiştir (Tablo 3.1). Bu nedenle, 10 m'lik Sentinel-2 bantları 2, 3, 4, 8, sırasıyla yüksek çözünürlüklü Planet Scope bantları 1, 2, 3, 4'e göre keskinleştirilmiştir. Ayrıca, 20-m Sentinel-2 bandı 8A, Planet Scope bandı 4'e göre keskinleştirilmiştir. Buna göre, 20-m mekânsal çözünürlüklü Sentinel-2 5, 6, 7, 11, 12 bantları denklem tarafından verilen sentezlenmiş bant (S) temelinde keskinleştirilmiştir:


$$S = \frac{B3+B4}{2} \quad (3.1)$$

B3 ve B4, sırasıyla Planet Scope bant 3 ve 4'ü temsil etmektedir. Görüntü keskinleştirme işlemi, açık kaynak yazılım Orfeo ToolBox (OTB) 8.1.2 sürümü kullanılarak gerçekleştirilmiştir. OTB algoritması Monteverdi uygulama arayüzünde çalıştırılmıştır.

Tablo 3.1. S2 bantlarının keskinleştirilmesinde pankromatik bant olarak kullanılan PS bantları

Sentinel-2		Planet Scope	
Mekansal Çözünürlük	Bantlar	Bantlar	Mekansal Çözünürlük
10 m	B2	B1	3 m
	B3	B2	
	B4	B3	
	B8	B4	
20 m	B8A	B4	3 m
	B5	$S = \frac{B3+B4}{2}$	
	B6		
	B7		
	B11		
	B12		

Tablo 3.1’de eşleştirildiği gibi Sentinel-2 10 m ve 20 m mekânsal çözünürlüklü bantları Planet 3 m çözünürlüklü bantları ile keskinleştirilmiştir. Bantların mekânsal olarak artan çözünürlüklerinin gözle gözlemlenir şekilde iyileşmektedir. Görsel 3.11’de Sentinel-2 Bant 7’nin farklı çözünürlükte ve planet ile keskinleştirilmiş görüntülerinde de görüldüğü gibi gözle ayırt edilebilir derecede mekânsal çözünürlüğü artmıştır.



Sentinel B7 / 20m

Sentinel B7 / 10 m

Pan Görüntü B7 / 3m

Görsel 3.11. S2 Bant 7’nin farklı çözünürlükte ve Planet ile keskinleştirilmiş görüntüleri



Görsel 3.12. Aynı alana ait S2 ve PS kırmızı bant ve keskinleştirilmiş pan görüntü

Görsel 3.12’de aynı alana ait iki görüntünün 20 m ve 3 m mekânsal çözünürlüğü ve pan-keskinleştirilmiş görüntü sunulmuştur. Gözle gözlemlenir mekânsal çözünürlük farkının yanı sıra zamansal olarak aynı fakat spektral ve radyometrik olarak farklı görüntülerin keskinleştirme sırasında etkileşiminden kaynaklı değişimler söz konusudur. Oluşan yeni görüntünün sınıflandırma olumlu veya olumsuz etkileri çalışma içerisinde analiz edilmektedir.

3.2.4. Bitki İndekslerinin Hesaplanması

Sınıflandırma işleminde Sentinel-2, Planet Scope ve Pan-keskinleştirilmiş görüntü olmak üzere 3 görüntü kullanılmıştır. Veri setlerinin hazırlanmasında her bir görüntünün bantları ve bu bantlardan üretilen indeksler kullanılmıştır. İndeks seçiminde öncelik indekslerin literatürdeki kullanımı ve tarım alanlarındaki başarısı olmuştur. Doğrudan tercih edilen indekslerin yanı sıra bitki örtüsü, orman, ağaç, toprak yapısı gibi yakın alanlarda sınıflandırma başarısı yüksek olan indekslerde çalışmaya dahil edilmiştir. Tablo 3.2’de formülleri ile belirtilen 27 adet indeks Sentinel-2 ve Planet Scope ile füzyon edilmiş Sentinel-2’nin Pan-keskinleştirilmiş görüntüleri için kullanılmıştır. Tablo 3.3’te gösterilen 10 adet formülle ise Planet Scope görüntülerinin sınıflandırmasında kullanılan indeksler üretilmiştir. Tablolardaki indekslere kullanılan farklı yazılımların doğru çalışması için indeks kodu verilmiştir. Tablo 3.2 ve Tablo 3.3’te bu eşleştirme gösterilmiştir.

Tablo 3.2. Sentinel-2 ve Pan-keskinleştirilmiş görüntüde kullanılan indeksler


İndeks Kodu	İndeks İsmi	İndeks Kısaltması	Formül
NDVI	Normalleştirilmiş Fark Bitki Örtüsü İndeksi	NDVI	$((B8-B4))/((B8+B4))$
Index3	Basit Oran İndeksi	SR	$((B8))/((B4))$
Index5	Toprak Düzeltilmiş Bitki Örtüsü İndeksi	SAVI	$(B8-B4)/(B8+B4+L) (1+L) (L=0,5)$
Index6	Norm İndeks	N-NIR	$B8/(B8+B4+B3)$
Index7	Yeşil Norm İndeksi	N-G	$B3/(B8+B4+B3)$
Index8	Normalize Fark İndeksi	ND	$(B8-B12)/(B8+B12)$
Index9	Normalize Fark İndeksi(R/G)	ND(R/G)	$(B4-B3)/(B4+B3)$
Index10	Kızılötesi Bitki Örtüsü İndeksi	IPVI	$(B8/((B8+B4)/2))(NDVI+1)$
Index11	Yoğunluk İndeksi		$(B4+B3+B2)/30.5$
Index12	Spesifik Yaprak Alanı İndeksi	SLA	$B8/(B4+B12)$
Index13	Dönüştürülmüş Bitki Örtüsü İndeksi	TVI	$\sqrt{((NDVI+0.5))}$
Index14	Klorofil İndeksi		$B8/B3-1$
Index15	Mavi Geniş Dinamik Aralık İndeksi		$(0,1B8-B2)/(0,1B8+B2)$
Index16	Pan NDVI		$(B8-(B4+B3+B2))/(B8+(B4+B3+B2))$
Index17	Yeşil Yaprak İndeksi	GLI	$(2*B3-B4+B2)/(2*B3+B4+B2)$
Index18	Klorofil Bitki örtüsü İndeksi		$B8 B4/ [B3]^2$
Index20	Normalize Fark Kızılötesi İndeksi	NDII	$((B8A-B11))/((B8A+B11))$
Index21	Geliştirilmiş Bitki Örtüsü İndeksi	EVI	$2,5*(B08- B04)/(B08 + 6*B04- 7.5*B02 + 1)$
Index22	Fark Bitki Örtüsü İndeksi	DVI	$B8-B4$
Index23	B7 Bantlı Yeşil Klorofil İndeksi		$(B07/B03)-1$
Index24	Optimize Edilmiş Toprak Ayarlı Bitki Örtüsü İndeksi	OSAVI	$1,16*((B7-B4))/((B7 + B4 + 0.16))$
Index25	Kanopi Klorofil İçerik İndeksi	CCCI	$((B7-B5)/(B7+ B5))/((B7-B4)/(B7+ B4))$
Index26	Yeşil Biyokütle İndeksi 2	GBM	$(B05-B03)/(B05+ B03)$
Index27	Modifiye Klorofil Emilim Oranı İndeksi	MCARI	$((B05-B04)-0.2*(B05-B03))*(B05/B04)$
Index28	Trans Klorofil Emilim Oranı İndeksi	TCARI	$3*[(B05-B04)-0.2*(B05-B03)*(B05/B04)]$
Index29	Üçgen Klorofil İndeksi	TCI	$1.2*(B05-B03)-1.5*(B04-B03)*\sqrt{((B05/B04))}$
Index30	Yeşil Bitki Örtüsü İndeksi	VIG	$(B03-B04)/(B03+ B04)$

Tablo 3.3. Planet Scope görüntüsünde kullanılan indeksler

İndeks Kodu	İndeks İsmi	İndeks Kısaltması	Formül
Index1	Normalleştirilmiş Fark Bitki Örtüsü İndeksi	NDVI	$((B4-B3))/((B4+B3))$
Index2	Yeşil-Kırmızı Normalleştirilmiş Fark İndeksi	GRND	$((B2-B3))/((B2+B3))$
Index3	Geliştirilmiş Bitki Örtüsü İndeksi	EVI	$2,5*(B4- B3)/(B4 + 6*B3- 7.5*B1 + 1)$
Index4	Basit Oran İndeksi	SR	$B4/B3$
Index5	Toprak Düzeltilmiş Bitki Örtüsü İndeksi	SAVI	$(B4- B3)/(B4-B3+L)*(1+L)$
Index6	Diferansiyel Bitki Örtüsü İndeksi	DVI	$B4-B3$
Index7	Atmosfere Dayanıklı Bitki Örtüsü İndeksi	ARVI	$(B4-(2*B3-B1))/(B4+(2*B3-B1))$
Index8	Yeşil Normalleştirilmiş Fark Bitki Örtüsü İndeksi	GNDVI	$((B4-B2))/((B4+B2))$
Index9	Geniş Dinamik Aralık Bitki Örtüsü İndeksi	WDRVI	$((0.1*B4-B3))/((0.1*B4+B3))$
Index10	Modifiye Toprak Ayarlı Bitki Örtüsü İndeksi	MSAVI	$(2*B4+1-\sqrt{((2*B4+1)^2-8(B4-B3))})/2$


3.2.5. Eğitim ve test veri setlerinin oluşturulması

Tez çalışması kapsamında kullanılacak parseller, bantlar ve bant indeksleri belirlendikten sonra tarım ürünlerinin tespitinde kullanılacak eğitim ve test veri setlerinin oluşturulması aşamasına geçilmiştir. Bu kapsamda çalışma sahası eğitim ve test alanı olarak iki ayrı alana bölünmüştür. Konumsal olarak benzer olan bu alanları ayrı iki alan olarak seçmekteki amaç modelin aynı havza içinde farklı alanlarda transfer edilebilir olmasını sağlamak içindir. Yapılan bölme işlemi sonucunda elde edilen parseller Görsel 3.13'te gösterilmiştir.




Görsel 3.13. Çalışma alanı olarak seçilen bölgedeki eğitim ve test parsellerinin dağılımı

Eğitim ve test alanlarında bulunan ürün parsellerinin sayısal olarak dağılımı Şekil 3.3'te sunulmuştur. Eğitim alanında toplamda 2468, test alanında 2039 parsel bulunmaktadır.



Şekil 3.3. Eğitim ve test alanı parsel sayılarının ürünlere göre dağılımı

Eğitim ve test parselleri elde edildikten sonra her bir uydu görüntüsüne ait bantların ve indekslerin ortalama değerlerinin parsellere yazdırılması aşamasına geçilmiştir. Bu aşamada ARCGIS 10.5 sürümü ModelBuilder üzerinden her bir veri için bu işlemi otomatik yapacak bir model geliştirilmiştir (Görsel 3.14). Bu model aracılığı ile manuel olarak en az 200 tekrar gerektiren parsellere bilgi yazdırma aşaması daha hızlı bir şekilde gerçekleştirilmiştir.



Görsel 3.14. Görüntü piksel değerlerinin ModelBuilder aracı ile hesaplanması

Her bir veri seti için elde edilen eğitim ve test Excel tabloları birleştirilip virgülle ayrılmış veri formatına dönüştürülerek makina öğrenme algoritmalarının çalıştırılacağı R Studio 3.3.0 için uygun hale getirilmiştir.

4. ARAŞTIRMA BULGULARI

Çalışma tarım alanlarının uzaktan algılama ve coğrafi bilgi teknolojileri yardımı ile ücretsiz veya düşük maliyetli, hızlı ve yüksek doğruluklu tespit ederek ve izleyerek gıda güvenliğinin sağlanmasına katkıda bulunmayı hedeflemiştir. Hedef doğrultusunda çalışmada Sentinel-2 ve Planet Scope görüntülerini doğrudan kullanımı ötesinde birbirine üstün yönleri bulunan bu iki görüntüden üretilen keskinleştirilmiş görüntünün de sınıflandırmaya katkısı araştırılmıştır. Toplam da Sentinel-2, Planet Scope ve Keskinleştirilmiş Pan-Görüntü olmak üzere üç farklı uydu görüntüsünden elde edilen veri setleri üzerinden çalışma yapılmıştır.

Sınıflandırma işleminde dört farklı makine öğrenme algoritmasından yararlanılmıştır. Bunlar Rastgele Orman (Random Forest), Destek Vektör Makinaları (SVM), En yakın Komşuluk (KNN) ve daha güncel bir algoritma olan XGBoost algoritmalarıdır. Algoritmaların tamamı her bir veri setine ait iki veri grubu ile çalışmaktadır. Eğitim verisi ile öğrenme gerçekleştirip test verisini tahmin yapılarak model doğrulama işlemi gerçekleştirilmektedir.

4.1. Makine Öğrenme Algoritmalarıyla Model Geliştirme ve Test


Rastgele Orman (Random Forest), Destek Vektör Makinaları (SVM), En yakın Komşuluk (KNN) ve XGBoost algoritmalarına ait kodlar açık kaynak kütüphanelerinden temin edilmiştir. Kodlar veri tabanına göre revize edilmiş ve uygun formatta düzenlenmiştir. Algoritmalar Sentinel-2, Planet Scope ve Pan keskinleştirilmiş görüntünden üç farklı veri seti için çalıştırılmıştır. Algoritmalara ait değişkenler, parametreler ve uygulama adımları detaylı incelenmektedir.

4.1.1. Rastgele orman (RO) algoritmalarının çalıştırılması

Rastgele Orman modelinde ayarlamanız gereken en önemli parametrelerden ikisi ağaç sayısı ve her bir tahminlemede kullanılan değişken sayısıdır. Ağaç sayısı (ntree) parametresi, son tahmini oluşturmak için birleştirilen basit modellerin veya karar ağaçlarının sayısını belirler. Bu sayı genelde 50-500 arasında seçilmektedir. Ağaç sayısını azalttıkça tahmin performansının azalacağı arttırdıkça da tahmin süresinin artacağı dikkate alınarak doğru sayı uygulanan projeye göre uygun şekilde seçilmelidir.

Mtry, ağaçlar oluşturulurken dikkate alınan özellik sayısıdır. Bu değer genellikle veri setleri içinde bulunan toplam değişkenlerin kare kökü olarak alınmaktadır. Ancak bu doğru sonuçların üretilmesi için farklı sayıda değişkenlerin denenmesi önemlidir. Mtry sayısı arttıkça seçimi etkileyen özelliklerin dikkate alınma ihtimali artar fakat rastgelelikte bu doğrultuda artmış olur. Mtry sayısını azalttıkça özellikler göz ardı edilir ve daha sabit sonuçlar ortaya çıkar. Bundan dolayı Mtry değerinin optimum olacak şekilde belirlenmesi önemlidir.

Rastgele orman algoritmanın tarımsal ürünlerin tespitindeki başarısını belirlemek için raster ve vektör verilerden elde edilen veri setleri önce Excel sonra CSV formatına aktarılarak R Studio programında işlenir hale getirilmiştir. Makine öğrenme algoritması, açık kaynak kütüphaneleri ve uygulamaya özel yazılan kodlar ile çalıştırılarak sınıflandırma işlemleri yapılmıştır. Görsel 4.1’te sağ üst tarafta veri tabanının, sol üst tarafta algoritmanın veri formatına uygun kodları, sol alt taraftaki kısımda ise sınıflandırma sonuçları bulunmaktadır.




Görsel 4.1. R Studio RO kodları ve veri seti örneği

Sonuç matrisleri Excel’e aktarılarak yine çalışmaya özel kodlanılan excel makro yazılımı ile “Genel Doğruluk” ve “Kappa” değerleri hesaplatılmıştır.

4.1.1.1. RO ile Sentinel-2 sonuçları

Çalışmada Sentinel 2 veri seti ile tarım parsellerinin tahminlemede kullanılan Rastgele Orman (RO) sınıflandırıcı modelini geliştirmek için öncelikle eğitim veri setinden optimum ağaç sayısı ve değişken sayısının tespit edilmesi gerçekleştirilmiştir. Eğitim veri seti k-katmanlı çapraz doğrulama (k-fold cross validation) işlemine tabi tutularak RO sınıflandırıcı modelde kullanılan parametrelerin tespiti yapılmıştır. Çapraz doğrulama aşamasında eğitim verisi 10 parçaya bölünmüş ve 3 tekrarlı doğrulama işlemi gerçekleştirilmiştir. Ağaç sayısı 50, 100, 200, 300, 400, 500, 600 ve 700 olarak test edilirken, değişken sayısı mtry 3'ten 15'e kadar birer birer artırılmıştır. Elde edilen sonuçlar çapraz doğrulamanın genel doğruluğu ve Kappa değerine göre değerlendirilmiştir. Çapraz doğrulama işlemine göre elde edilen sonuçlar Görsel 4.1'de verilmiştir. Şekil 4.1 incelendiğinde tüm ağaç sayılarında %85 ile %86 genel doğruluk arasında sonuçlar elde edildiği görülmüştür. En optimum değer 400 ağaç ve 5 değişken uygulandığında görülmüştür. Bu değerde genel doğruluk %85,7 Kappa değeri 0.804 olarak elde edilmiştir.




Şekil 4.1. S2 veri seti için geliştirilen RO sınıflandırıcının optimum parametre seçimi

En yüksek doğruluk metriğini veren ağaç sayısı ve değişken sayısı sınıflandırıcı modele uygulanarak model eğitilmiştir. Eğitilen model ise çalışmada kullanılan Sentinel-2 test veri setine uygulanarak doğruluk analizi işlemi gerçekleştirilmiştir. Elde edilen sonuçlar Tablo 4.1’de sunulmuştur. Tablo incelendiğinde domates parsellerinin üretici doğruluğu %52, üzüm parsellerinin kullanıcı doğruluğu %73 olarak elde edilmiştir. Burada özellikle domates parsellerinin üzüm parseli olarak tahminlendiği tabloda görülmektedir. Bu durum da üzüm parsellerinin kullanıcı doğruluğunu düşürmektedir. Diğer tarım ürünlerinin tahminleme doğruluklarının %84 üzerinde olduğu görülmektedir. Algoritmanın test veri setini tahminleme başarısına bakıldığında genel doğruluk %84 Kappa değeri 0,79 olarak elde edilmiştir.

Tablo 4.1. RO sınıflandırıcısının S2 test parsellerinde tahminleme sonuçları

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	131	6	0	0	2	139	0,942
	Mısır	17	673	22	17	7	736	0,914
	Pamuk	26	26	301	2	0	355	0,848
	Üzüm	70	57	30	457	14	628	0,728
	Zeytin	6	8	3	11	153	181	0,845
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,524	0,874	0,846	0,938	0,869		
	Genel Doğruluk							84,11%
	Kappa Katsayısı							0,79


RO Sentinel-2 sınıflandırıcı modelin test verisine uygulanması ile tahminlenen parseller ve test verisindeki parsellerin gerçek ürün bilgileri Görsel 4.2’de sunulmuştur. Görsel incelendiğinde domates alanlarındaki tahminlemenin zayıflığı göze çarparken, diğer alanların gerçeğe yakın olarak çıkarıldığı görülmektedir.



Görsel 4.2. RO sınıflandırıcı ile S2 test veri setinden tahminlenen parseller

4.1.1.2. RO ile Planet Scope sonuçları

Planet Scope veri seti üzerinden tarım parsellerin RO algoritması ile tahminlenmesinde kullanılan sınıflandırıcın geliştirilmesi için Planet Scope eğitim veri setine 10-katmanlı 3 tekrarlı çapraz doğrulama uygulanmıştır. Bu aşamada RO algoritmasında kullanılan ağaç sayısı 50, 100, 200, 300, 400, 500, 600 ve 700 olarak veri setine uygulanırken, ağaçları oluşturmada kullanılan değişken sayıları 2’den 10’a kadar birer birer artırılarak optimum parametrenin seçilmesi için algoritma çalıştırılmıştır. Yapılan çapraz doğrulama sonucunda her bir ağaç sayısı ve değişken sayısına göre elde edilen genel doğruluk ve kappa değerleri Şekil 4.2’de gösterilmiştir. Görsel incelendiğinde farklı ağaç sayısı ve değişken sayılarında çok yakın sonuçlar elde edildiği görülmektedir. En iyi sonuca ağaç sayısı 200 ve değişken sayısı 5 olarak seçildiğinde ulaşılmıştır. Bu değerlere göre çapraz doğrulama aşamasında genel doğruluk %82.30, kappa değeri 0.756 olarak elde edilmiştir.




Şekil 4.2. PS veri seti için geliştirilen RO sınıflandırıcının optimum parametre seçimi

Parametre optimizasyonunda elde edilen optimum ağaç sayısı = 200 ve ağaç oluşturmada kullanılan değişken sayısı Mtry = 5 eğitim veri setine uygulanarak Planet Scope veri seti için RO sınıflandırıcı model geliştirilmiş ve geliştirilen model test veri setine uygulanmıştır. Test veri setinde yapılan tahminleme ile elde edilen tarım parseli sınıfları test verisin gerçek parsel ürün bilgileri ile karşılaştırılarak hata matrisine göre doğruluk analizi yapılmıştır. Elde edilen sonuçlar Tablo 4.2’de sunulmuştur. Tablo incelendiğinde domates ürünün üretici doğruluğu %10 olarak elde edilmiştir. Bu ürüne ek olarak pamuk bitkisinin üretici doğruluğu %62, üzüm bitkisinin kullanıcı doğruluğu %65 olarak elde edilmiştir. Bunların dışında diğer ürünlerin doğruluk değerleri %77 üzerinde tahminlenmiştir. RO sınıflandırıcının PlanetScope test verisi üzerindeki genel tahminleme başarısı genel doğrulukta %74, Kappa değerinde 0.63 olarak elde edilmiştir. Hata matrisi irdelendiğinde domates bitkisinin büyük bölümü üzüm olarak tahminlendiği görülmektedir. Ayrıca pamuk bitkisine ait 99 parselinde mısır olarak sınıflandırıldığı görülmektedir.

Tablo 4.2. RO sınıflandırıcının PS test parsellerinde tahminleme sonuçları

		Referans Veri						
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	28	3	0	5	0	36	0,778
	Mısır	42	685	99	42	3	871	0,786
	Pamuk	39	19	223	2	0	283	0,788
	Üzüm	131	52	30	415	13	641	0,647
	Zeytin	10	11	4	23	160	208	0,769
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,112	0,890	0,626	0,852	0,909		
	Genel Doğruluk							74,10%
						Kappa Katsayısı		0,63


RO sınıflandırıcının Planet Scope test verisine uygulanması ile tahminlenen parseller ve test sahasının gerçek parsel dağılımını gösteren referans veri seti Görsel 4.3’te sunulmuştur. Görsel incelendiğinde domates parsellerin oldukça az sayıda tahminlendiği görselden de anlaşılmaktadır.



Görsel 4.3. RO sınıflandırıcı ile PS test veri setinden tahminlenen parseller

4.1.1.3. RO ile Pan-Keskinleştirme sonuçları

RO ile Pan-Keskinleştirme veri seti için sınıflandırıcı model geliştirmede diğer iki veri setinde olduğu gibi 10 katmanlı ve 3 tekrarlı çapraz doğrulama ile öncelikle parametre optimizasyonu yapılmıştır. Bu kapsamda RO'un ağaç sayısı 50, 100, 200, 300, 400, 500, 600 ve 700 ağaç olacak şekilde, değişken sayısı 3'ten 15'e kadar birer artacak şekilde algoritmaya uygulanmıştır. Yapılan çapraz doğrulama uygulamasında genel doğruluk ve Kappa kat sayısındaki değişimlere göre elde edilen sonuçlar Şekil 4.3'de sunulmuştur. Şekil irdelendiğinde gerek genel doğruluk gerekse Kappa değerleri farklı ağaç ve değişken sayısında yakın sonuçlar vermektedir. Pan-Keskinleştirme eğitim verisi için en iyi sonuçlar ağaç sayısı 500 ve değişken sayısı 7'de elde edilmektedir. Bu parametre değerlerinde genel doğruluk % 86.01, Kappa değerinin 0.807 olarak elde edilmiştir.




Şekil 4.3. Pan-Keskinleştirme veri seti için geliştirilen RO sınıflandırıcının optimum parametrelerinin belirlenmesi

Elde edilen optimum parametre değerleri eğitim veri setine uygulanarak Pan-Keskinleştirme veri seti için RO sınıflandırıcı model geliştirilmiştir. Bu modelin test veri setine uygulanması ile elde edilen hata matrisi Tablo 4.3’de sunulmuştur. Tablo irdelendiğinde Pan-Keskinleştirme veri seti ile Sentinel-2 veri setinden hemen hemen benzer doğruluk değerleri elde edilmiştir. Pan-Keskinleştirme veri seti için geliştirilen RO algoritmasının tahminlemeyi iyileştirici bir etkisi olmamıştır. Test verisindeki domates parsellerinde %50 üzerinde başarı elde edilmiştir. Planet Scope veri setinden oldukça fazla bir doğrulukla parsel tahminlenmiştir.

Tablo 4.3. RO sınıflandırıcının Pan-Keskinleştirme test parsellerinde tahminleme sonuçları

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	130	7	3	2	2	144	0,903
	Mısır	19	672	24	16	6	737	0,912
	Pamuk	21	23	294	2	0	340	0,865
	Üzüm	71	60	32	451	11	625	0,722
	Zeytin	9	8	3	16	157	193	0,813
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,520	0,873	0,826	0,926	0,892		
	Genel Doğruluk							83,57%
	Kappa Katsayısı							0,78


Pan-Keskinleştirme test veri seti için tahminlenen parsellerin, test verisinin referans parselleri ile karşılaştırılması için oluşturulan durum Görsel 4.4’de sunulmuştur.



Görsel 4.4. RO sınıflandırıcı ile Pan-Keskinleştirme test veri setinden tahminlenen parseller

4.1.2. Destek vektör makinaları (DVM) algoritmasının çalıştırılması

DVM yöntemi kullanılarak tarım parsellerinin tahminlemede kullanılan sınıflandırıcı modelin geliştirilmesi için öncelikle algoritmada sınıflandırmaya etki eden optimum C parametresi ve Gamma parametresi belirlenmeye çalışılmıştır. Bu doğrultuda eğitim verilerine k-katmanlı çapraz doğrulama ile C değeri 1 ile 2^9 arasında 2'nin katları olacak şekilde, gamma değeri 0-1 arasında 0.1 artırılarak hatanın azalmasına göre modele olan etkileri incelenmiştir. Elde edilen optimum C değeri ve Gamma değeri ile DVM sınıflandırıcı modeller geliştirilmiş ve bu modeller test veri setlerine uygulanarak modellerin başarısı gözlemlenmiştir. DVM yöntemi radyal temelli fonksiyon (RBF: Radial Basis Function) olarak tüm veri setlerine uygulanmıştır. Görsel 4.5'te R Studio yazılımının uygulama görselinde sol taraf algoritma kodlarını sağ taraf veri setini göstermektedir.




Görsel 4.5. R Studio SVM Kodları ve Veri Seti

4.1.2.1. DVM ile Sentinel-2 sonuçları

Sentinel-2 eğitim veri seti için öncelikle 10 katmanlı çapraz doğrulama işlemi veri setine uygulanmıştır. Bu işlemde C değerleri 1 ve 2^9 aralığında 2'nin katları olacak şekilde gamma değeri 0-1 arasında 0.1 artırılarak parametre optimizasyonu gerçekleştirilmiştir. Verilen C ve gamma değerlerine göre elde edilen sonuçlar Şekil 4.4'te gösterilmiştir. Yapılan parametre optimizasyonu işleminde en düşük hata miktarı (0.133) gamma = 0.1,

C = 4 değerlerinden elde edilmiştir. Bu değerlerin eğitim veri setine uygulanması ile Sentinel-2 veri seti için DVM sınıflandırıcı model geliştirilmiştir.




Şekil 4.4. Sentinel-2 veri seti için optimum C ve gamma parametresinin belirlenmesi

Optimum parametrelere ile geliştirilen DVM sınıflandırıcısının test alanına ait veri setine uygulanması ile elde edilen hata miktarları Tablo 4.4'te gösterilmiştir. Elde edilen sonuçlar irdelendiğinde tüm ürünlerin tahminlemede kullanıcı doğruluklarının %70 üzerinde olduğu, üretici doğruluklarında ise sadece domates ürününde %62, diğerlerin %80 üzerinde olduğu görülmektedir. Sentinel-2 veri seti için geliştirilen DVM sınıflandırıcısının test alanına ait parselleri genel doğruluk %85 ve Kappa değeri 0.79 olarak yüksek değerlerde tahminlendiği görülmektedir.

Tablo 4.4. Gamma:0.1, Cost:4 değişken değerleri ile sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	121	15	2	1	6	178	0,865
	Mısır	15	668	18	12	9	729	0,916
	Pamuk	42	15	310	3	0	338	0,917
	Üzüm	61	58	22	445	14	590	0,754
	Zeytin	11	17	4	20	143	197	0,726
	Toplam	250	773	356	481	172	2032	
	Üretici D.	0.484	0,864	0,871	0,925	0,831		
	Genel Doğruluk							85.09%
Kappa Katsayısı							0,79	


Sentinel-2 test sahası için DVM Sınıflandırıcı ile elde edilen sonuçlar Görsel 4.6'da sunulmuştur.



Görsel 4.6. DVM Sınıflandırıcının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.2.2. DVM ile Planet Scope sonuçları

Planet Scope görüntülerinden oluşturulan veri setine ait eğitim verisi üzerinden DVM sınıflandırma modelinin geliştirilmesi 10 katmanlı çapraz doğrulama işlemi gerçekleştirilmiştir. Bu aşamada da Sentinel-2 veri setinden olduğu gibi gamma değeri 0-1 arasında 0,1 artırılmış, C parametresi $1-2^9$ arasında ikinin katları olarak değiştirilmiştir. Verilen gamma ve C parametresi kombinasyonlarına göre elde hatanın azalması Şekil 4.5'te gösterilmiştir. Uygulama sonucunda gamma=0.3, C=16 değerlerinde en düşük hata değerine (0.165) ulaşılmıştır. Çapraz doğrulamada elde edilen optimum parametrelere Sınıflandırıcı modelin geliştirilmesi için kullanılmıştır.




Şekil 4.5. PS veri seti için optimum C ve gamma parametresinin belirlenmesi

Optimum parametrelerin uygulanması ile geliştirilen DVM sınıflandırıcı model test alanına ait veri setine uygulanmıştır. Test alanından tahminlenen parsellerle referans parsellerin karşılaştırılması ile elde edilen hata matrisi Tablo 4.5'de verilmiştir. Tablo incelendiğinde domates parsellerinin üretici doğruluğun çok düşük olduğu görülmektedir. Pamuk ürününün üretici doğruluğu, üzüm bitkisinin ise kullanıcı doğruluğu %70 altında kalmıştır. Sınıflandırmanın genel başarısını gösteren genel doğruluk değeri %75, Kappa kat sayısı 0,66 olarak elde edilmiştir. DVM sınıflandırıcı ile Planet Scope verilerinden tarım parsellerinin tahminlenmesi verilerine göre daha az başarı ile gerçekleşmiştir.

Tablo 4.5. gamma:0.3, Cost:16 değişken değerleri ile sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	24	2	0	2	0	28	0,857
	Mısır	24	674	75	20	3	796	0,847
	Pamuk	38	17	234	4	0	293	0,799
	Üzüm	153	64	44	440	10	711	0,619
	Zeytin	11	13	3	21	163	211	0,773
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,096	0,875	0,657	0,903	0,926		
	Genel Doğruluk							75,28%
							Kappa Katsayısı	0,66


Planet Scope test verisi için DVM sınıflandırıcının uygulanması ile tahminlenen parsellerin referans parsellerin gerçek değerleri ile görsel karşılaştırması Görsel 4.7’de sunulmuştur.



Görsel 4.7. DVM Sınıflandırıcının PS test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.2.3. DVM ile Pan-Keskinleştirme sonuçları

Pan-Keskinleştirme veri setine ait eğitim verisini kullanarak DVM sınıflandırıcı modelini geliştirmek için optimum parametrelerinin belirlenmesinde 10-katmanlı çapraz doğrulama işlemi uygulanmıştır. Bu işlem doğrultusunda C ve gamma değerleri önceki veri setlerinde olduğu gibi benzer aralıklarda değiştirilerek Pan-keskinleştirme veri setine uygulanmıştır. Yapılan çapraz doğrulama aşamasında veri seti için optimum gamma değeri 0.1, optimum C değeri 16 olarak elde edilmiş, bu değerde en düşük hata değeri 0.124 olarak elde edilmiştir (Şekil 4.6).




Şekil 4.6. DVM ile Pan-Keskinleştirme veri seti için optimum gamma ve C parametrelerinin seçimi

Optimum parametrelerin eğitim veri setine uygulanması ile Pan-Keskinleştirme veri seti için DVM sınıflandırıcı model geliştirilmiştir. Bu model test sahasına ait parsellere uygulanmış, tahminlenen parseller referans veri seti ile karşılaştırılarak hata matrisi elde edilmiştir. Elde edilen hata matrisi irdelendiğinde, domates parsellerinin üretici doğruluğu %66 olarak elde edilmiş, bu değer dışında hemen hemen tüm doğruluk metriklerinde %80 üzerinde başarı yakalanmıştır. DVM pan keskinleştirici sınıflandırma modelinin genel doğruluğu %87, kappa değeri 0,83 olarak elde edilmiştir (Tablo 4.6). Bu değerler tüm sınıflandırıcılar içinde en yüksek değerlerdir.

Tablo 4.6. gamma:0.1, Cost:16 değişken değerleri ile sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	167	14	1	1	5	187	0,888
	Mısır	18	677	18	11	4	729	0,929
	Pamuk	5	18	316	3	1	343	0,921
	Üzüm	53	49	19	458	8	588	0,779
	Zeytin	7	12	2	14	158	192	0,823
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0.668	0,879	0,888	0,940	0,898		
	Genel Doğruluk							87,20%
							Kappa Katsayısı	0,83

DVM sınıflandırıcısı ile test alanından tahminlenen parseller ile referans parsellerin karşılaştırmalı sunumu Görsel 4.8’de sunulmuştur. Görsel incelendiğinde tahminleme parsellerinin gerçek parsellere yakın bir görsel sunumda olduğu görülmektedir.




Görsel 4.8. DVM Sınıflandırıcının *Pan-Keskinleştirme* test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.3. En yakın komşuluk (KNN) algoritması ile tahminleme

Bu algoritmada en temel değişken olan K değeri, sınıflandırması planlanan piksel veya nesnenin komşularını ne kadar olacağını belirlemektedir. K değerinin belirlenmesi için eğitim veri setleri üzerinde K-katlı çapraz doğrulama işlemi gerçekleştirilmiştir. Bu işlem doğrultusunda her bir veri setinde K değerine farklı değerler vererek en iyi sonucu veren K değeri sınıflandırıcı modelin geliştirilmesinde kullanılmış ve bu KNN sınıflandırıcı modeller test verilerine uygulanmıştır.

4.1.3.1. KNN ile Sentinel-2 sonuçları

Sentinel-2 veri seti için eğitim verisinden sınıflandırıcı modelin geliştirilmesinde K değeri 1-20 arasında birer artırılarak uygulanmıştır. Yapılan 10 parçalı, 3 tekrarlı çapraz doğrulama sonucunda en uygun K değeri 7 olarak elde edilmiştir (Şekil 4.7). K=7 değeri ile eğitim verisi için en iyi genel doğruluk %84, en iyi Kappa değeri 0.78 elde edilmiştir.



Şekil 4.7. KNN algoritması ile S2 eğitim veri setinden geliştirilen sınıflandırıcı için en iyi K değerinin seçilmesi


K=7 değerine göre geliştirilen sınıflandırıcı model Sentinel-2 verisine göre oluşturulan test alanına ait veri setine uygulanmıştır. Uygulama sonucu tahminlenen tarım parselleri ile referans verinin karşılaştırılması ile elde edilen doğruluk analizi sonuçları Tablo 4.7’de gösterilmiştir. Tablo 4.7 incelendiğinde Domates parsellerinin üretici doğruluklarının çok düşük olduğu, bunun dışında diğer ürünlerin gerek kullanıcı doğruluklarının gerekse üretici doğruluklarının yüksek olduğu gözlemlenmiştir. Sentinel-

2 veri seti için geliştirilen KNN sınıflandırıcı modelin test alanı üzerindeki genel doğruluğu %80,87 Kappa değeri 0,74 olarak elde edilmiştir.

Tablo 4.7. K=7 değişken değerleri ile sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	81	5	1	0	1	88	0,920
	Mısır	18	672	26	13	3	732	0,918
	Pamuk	34	18	286	1	0	339	0,844
	Üzüm	105	62	39	450	12	668	0,674
	Zeytin	12	13	4	23	160	212	0,755
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,324	0,873	0,803	0,924	0,909		
	Genel Doğruluk							80,87%
Kappa Katsayısı							0,74	


Yapılan test işlemi sonucu tahminlenen parseller ile referans parsellerin karşılaştırılmalı gösterimi Görsel 4.9’da sunulmuştur. Şekil incelendiğinde Domates referans verideki domates alanları ile sınıflandırma sonucu tahminlenen domates parsellerindeki farklılık net olarak görülmektedir (Görsel 4.9).



Görsel 4.9. KNN-Sınıflandırıcının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.3.2. KNN ile Planet Scope sonuçları

Planet Scope veri seti için eğitim verisi kullanılarak KNN sınıflandırıcı modelin geliştirilmesinde ilk olarak önceki uygulamalara benzer şekilde en uygun K değerinin bulunması hedeflenmiştir. Bu kapsamda k-katmanlı çapraz doğruluma 10 katman ve 3 tekrarlı şekilde K değeri 1-20 arasında 1'er artacak şekilde eğitim veri setine uygulanmıştır. Genel doğruluk ve Kappa değerindeki artış ve azalışlara göre en uygun K parametresi 11 olarak elde edilmiştir (Şekil 4.8). Uygulamada diğer K değerleri incelendiğinde K=7'den sonra Kappa ve Genel doğruluk değerleri çok yakın gelmektedir. K=11'den sonra bu değerler düşüşe geçmektedir.



Şekil 4.8. Planet Scope veri seti için en uygun K değerinin belirlenmesi


Belirlenen K=11 eğitim verisine uygulanarak Planet Scope veri seti için KNN-Sınıflandırıcı modeli oluşturulmuştur. Bu model test veri setine uygulandığında Tablo 4.8'de gösterilen doğruluk değerleri elde edilmiştir. Tablo 4.8 incelendiğinde diğer uygulamalarda olduğu gibi domates ürününün tahminlenmesinde üretici doğruluğu çok düşük olarak elde edilmiştir. Pamuk verisinin üretici doğruluğu %61 olarak görülmektedir. Üzüm verisinin kullanıcı doğruluğu ise %66 olarak elde edilmiştir. Bu ürünler dışında diğer ürünlerde %70 üzerinde hem kullanıcı hem de üretici doğruluğunda

başarı yakalanmıştır. Sınıflandırıcının test verisi üzerindeki genel doğruluğu %76, Kappa değeri ise 0,67 olarak elde edilmiştir.

Tablo 4.8. *K=11 Değişken değerine göre KNN ile Planet Scope test verisi tahminleme sonuçları*

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	49	4	1	4	1	59	0,831
	Mısır	31	678	107	15	3	834	0,813
	Pamuk	30	18	217	3	0	268	0,810
	Üzüm	129	58	28	446	18	679	0,657
	Zeytin	11	12	3	19	154	199	0,774
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,196	0,881	0,610	0,916	0,875		
	Genel Doğruluk							75,72%
Kappa Katsayısı							0,67	


KNN Sınıflandırıcının Planet Scope test verisine uygulanması ile elde edilen sonuçlar Görsel 4.10'da gösterilmiştir. Referans veri ile tahminlenen parseller karşılaştırıldığında domates alanlarında Planet Scope ve KNN sınıflandırıcı kombinasyonun yeterince başarılı olmadığı görülmektedir.



Görsel 4.10. KNN-Sınıflandırıcının PS test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.3.3. KNN Pan-Keskinleştirme sonuçları

Pan-Keskinleştirme eğitim veri setini kullanılarak geliştirilecek KNN sınıflandırma modeli için en uygun K değeri K-katmanlı çapraz doğrulama ile k değerini 1’den 20’ye kadar değiştirerek 10 katmanlı 3 tekrarlı olarak gerçekleştirilmiştir. Yapılan test işlemi sonucunda en uygun K değeri Pan-Keskinleştirme veri seti için 9 olarak elde edilmiştir (Şekil 4.9). Dokuz değerine göre çapraz doğrulama işleminde genel doğruluk 0.84 Kappa değeri 0,78 olarak elde edilmiştir.




Şekil 4.9. Planet Scope veri seti için en uygun K değerinin belirlenmesi

Belirlen K = 9 değerine göre eğitim verisinde KNN ile Pan-Keskinleştirme sınıflandırma modeli üretilmiştir. Bu modelin test alanına uygulanması ile elde edilen sonuçlar Tablo 4.9’da gösterilmiştir. Tablo incelendiğinde domates parsellerinin üretici doğruluğunun çok düşük olduğu ancak Sentinel-2 ve Planet Scope veri setlerine göre daha yüksek doğruluğa sahip olduğu görülmektedir. Üzüm parsellerinin kullanıcı doğruluğu %67 olarak elde edilmiştir. Bunların dışındaki diğer doğruluk değeri %75 üzerinde elde edilmiştir. KNN Pan-Keskinleştirme sınıflandırıcı ile gerçekleştirilen sınıflandırma işleminde genel doğruluk (%82) ve kappa (0.76) değerleri diğer iki veri setine göre daha yüksek değerler olarak elde edilmiştir. Burada Sentinel-2 görüntülerinin Planet Scope ile keskinleştirilmesinin doğruluğu artırdığı söylenebilir.

Tablo 4.9. *k=9* değışken değeri ile sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	107	6	2	1	0	116	0,922
	Mısır	14	665	17	10	5	711	0,935
	Pamuk	16	21	294	1	0	332	0,886
	Üzüm	103	65	40	454	13	675	0,673
	Zeytin	10	13	3	21	158	205	0,771
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,428	0,864	0,826	0,932	0,898		
	Genel Doğruluk							82,30%
Kappa Katsayısı							0,76	

K=9 değeri KNN Pan-Keskinleştirme sınıflandırıcısına göre test alanında bulunan parsellerin tahminlemesi ile elde edilen parsellerin dağılımı Görsel 4.11’de sunulmuştur.



Görsel 4.11. KNN-Sınıflandırıcının *Pan-Keskinleştirme* test veri setine uygulanması ile tahmin edilen parsel sınıfları


4.1.4. XGBoost algoritmalarının çalıştırılması

Bu algoritma sınıflandırma ve özellik seçimi çalışmalarında kullanılan en modern algoritmalarından birisidir. Çok görüntülü ve çok parametrelili gerçek bir uzaktan algılama sınıflandırılmasında kullanılması hem algoritmanın görüntü sınıflandırmada kullanılması hem de görüntü sınıflandırma işlemlerinde kullanılan yeni bir algoritma olması açısından önem arz etmektedir.

Algoritmada birden fazla değişken olması ve değişkenlerin uygulamaya göre deneme yanılma yöntemi ile belirleniyor olması onlarca kombinasyonla bir o kadar sonuç üretilmesine sebep olmuştur. Parametre değişkenlerine göre üretilen sonuçlar tablolarının en yüksek genel doğruluk ve kappa değerli olanlarının detay tabloları sunulmuştur.

4.1.4.1. XGBoost ile Sentinel-2 sonuçları

Algoritmada ağaç dallarının sayısını ve derinliğini belirleyen iterasyon değeri, dalların ne kadar hassasiyete budanacağına etkili olan gamma değeri, aşırı öğrenmeyi engelleyen lamda değerleri genel doğruluğu etkileyen temel faktörlerdir. En önemli parametre değeri rastgele orman algoritmasındaki ağaç sayısına benzeyen iterasyon değerinin belirlenmesidir. Çalışmada S2 verisinin eğitim verisi için optimum iterasyon sayısını belirlemek için mround parametresi 500 olarak verilmiştir. Eğitim seti default değerlere göre eğitim ve test olarak ikiye ayrılarak her bir iterasyonda algoritmanın eğitim ve test verilerini tahminlemedeki en düşük hata miktarı izlenmiştir (Şekil 4.10).



Şekil 4.10. S2 eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi


Bu kapsamda sınıflandırıcı modelin geliştirilmesinde en düşük hata değerini (0.1525) veren 254 iterasyon sayısı olarak uygulanmıştır. Algoritmanın diğer parametreleri farklı değerler verilerek doğruluğa etkisi araştırılmıştır. Eta parametresi dışındaki diğer parametreler default değerler olarak alınması uygun görülmüştür. Eta değeri ise 0,04 olarak sınıflandırıcı modele uygulanmıştır.

Belirlenen optimum parametre değerlerine göre Sentinel-2 seri seti için geliştirilen XGBoost sınıflandırıcı model test sahasına ait veri setine uygulanarak parsellerin tahminlemesi gerçekleştirilmiştir. Yapılan tahminleme sonucunda elde edilen doğruluk değerleri Tablo 4.10'da gösterilmiştir. Tabloda verilen sonuçlar incelendiğinde diğer algoritmalarda olduğu gibi XGBoost algoritması ile de domates parsellerini tahminlemede üretici doğruluğu %53 olarak elde edilmiştir. Üzüm parsellerinin kullanıcı doğruluğu %72 olarak elde edilmiştir. Bu değerlerin dışında diğer kullanıcı ve üretici doğrulukları %85 üzerinde tahminlenmiştir. XGBoost Sentinel-2 veri sınıflandırıcısının genel doğruluğu %85, Kappa değeri 0.80 olarak elde edilmiştir.

Tablo 4.10. XGBoost algoritması ile S2 test alanı sonuçları (eta:0,04; iterasyon: 254)

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	132	8	1	0	1	142	0,930
	Mısır	17	673	15	14	6	725	0,928
	Pamuk	19	21	306	1	0	347	0,882
	Üzüm	74	60	31	463	12	640	0,723
	Zeytin	8	8	3	9	157	185	0,849
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,528	0,874	0,860	0,951	0,892		
	Genel Doğruluk							84,89%
Kappa Katsayısı							0,80	

XGBoost sınıflandırıcısının test sahasına uygulanması ile elde tahminlenen parseller ve bu parsellerin gerçek referansları görsel olarak Görsel 4.12'de sunulmuştur.




Görsel 4.12. Xgboost sınıflandırıcının S2 test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.4.2. XGBoost ile Planet Scope sonuçları

Çalışmada Planet Scope verisinin eğitim verisi için optimum iterasyon sayısını belirlemek için mround parametresi 500 olarak verilmiştir. Eğitim seti default değerlere göre eğitim ve test olarak ikiye ayrılarak her bir iterasyonda algoritmanın eğitim ve test verilerini tahminlemedeki en düşük hata miktarı izlenmiştir (Şekil 4.11). Bu kapsamda sınıflandırıcı modelin geliştirilmesinde en düşük hata değerini (0.25608) veren 24 iterasyon sayısı olarak uygulanmıştır. Algoritmanın diğer parametreleri farklı değerler verilerek doğruluğa etkisi araştırılmıştır. Eta ve depth parametresi dışındaki diğer parametreler default değerler olarak alınması uygun görülmüştür. Eta değeri 0,01 olarak depth değeri ise 4 sınıflandırıcı modele uygulanmıştır.

Belirlenen optimum parametre değerlerine göre Planet Scope veri seti için geliştirilen XGBoost sınıflandırıcı model test sahasına ait veri setine uygulanarak parsellerin tahminlemesi gerçekleştirilmiştir. Yapılan tahminleme sonucunda elde edilen doğruluk değerleri Tablo 4.11’de gösterilmiştir.




Şekil 4.11. PS eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi

Tabloda verilen sonuçlar incelendiğinde diğer algoritmalarda olduğu gibi XGBoost algoritması ile de Domates parsellerini tahminlemede üretici doğruluğu %13 olarak elde edilmiştir. Pamuk parsellerinin kullanıcı doğruluğu %58 olarak elde edilmiştir. Bu değerlerin dışında diğer kullanıcı ve üretici doğrulukları %85 üzerinde tahminlenmiştir. XGBoost Planet Scope veri sınıflandırıcısının genel doğruluğu %74, kappa değeri 0,64 olarak elde edilmiştir.

Tablo 4.11. *eta:0,01; max.depth:4; iterasyon 24 parametrelili sınıflandırma sonucu*

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	34	3	1	2	0	40	0,850
	Mısır	37	688	116	42	7	890	0,773
	Pamuk	31	18	207	3	0	259	0,799
	Üzüm	137	50	30	427	13	657	0,650
	Zeytin	11	11	2	13	156	193	0,808
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,136	0,894	0,581	0,877	0,886		
	Genel Doğruluk							74,15%
	Kappa Katsayısı							0,64


XGBoost sınıflandırıcısının test sahasına uygulanması ile elde tahminlenen parseller ve bu parsellerin gerçek referansları görsel olarak Görsel 4.13’de sunulmuştur.



Görsel 4.13. Xgboost sınıflandırıcının Planet test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.1.4.3. Xgboost ile Pan-Keskinleştirme sonuçları

Çalışmada Pan-Keskinleştirme eğitim verisi için optimum iterasyon sayısını belirlemek için mround parametresi 500 olarak verilmiştir. Eğitim seti default değerlere göre eğitim ve test olarak ikiye ayrılarak her bir iterasyonda algoritmanın eğitim ve test verilerini tahminlemedeki en düşük hata miktarı izlenmiştir (Şekil 4.12). Bu kapsamda Sınıflandırıcı modelin geliştirilmesinde en düşük hata değerini (0. 0.14909) veren 34 iterasyon sayısı olarak uygulanmıştır. Algoritmanın diğer parametreleri farklı değerler verilerek doğruluğa etkisi araştırılmıştır. Eta ve depth parametresi dışındaki diğer parametreler default değerler olarak alınması uygun görülmüştür. Eta değeri 0,3 olarak depth değeri ise 6 değeri ile sınıflandırıcı modele uygulanmıştır.



Şekil 4.12. S2 eğitim verisinden geliştirilen XGBoost sınıflandırıcı için optimum iterasyon sayısının belirlenmesi


Belirlenen optimum parametre değerlerine göre Pan-Keskinleştirme veri seti için geliştirilen XGBoost sınıflandırıcı model test sahasına ait veri setine uygulanarak parsellerin tahminlemesi gerçekleştirilmiştir. Yapılan tahminleme sonucunda elde edilen doğruluk değerleri Tablo 4.12’de gösterilmiştir. Tabloda verilen sonuçlar incelendiğinde

diğer algoritmalarda olduğu gibi XGBoost algoritması ile de Domates parsellerini tahminlemede üretici doğruluğu %56 olarak elde edilmiştir. Üzüm parsellerinin kullanıcı doğruluğu %75 olarak elde edilmiştir. Bu değerlerin dışında diğer üretici doğrulukları %82 üzerinde tahminlenmiştir. XGBoost Pan-Keskinleştirme veri sınıflandırıcısının genel doğruluğu %85, Kappa değeri 0,80 olarak elde edilmiştir.

Tablo 4.12. İterasyon 34, eta: 0.3 eta:0,05; depth:6 parametrelili sınıflandırma sonucu

		Referans Veri					Toplam	Kullanıcı D.
		Domates	Mısır	Pamuk	Üzüm	Zeytin		
Sınıflandırma	Domates	140	7	1	0	1	149	0,940
	Mısır	20	679	24	19	6	748	0,908
	Pamuk	15	22	301	1	0	339	0,888
	Üzüm	65	54	27	453	7	606	0,748
	Zeytin	10	8	3	14	162	197	0,822
	Toplam	250	770	356	487	176	2039	
	Üretici D.	0,560	0,882	0,846	0,930	0,920		
	Genel Doğruluk							85,09%
	Kappa Katsayısı							0,80

XGBoost sınıflandırıcısının test sahasına uygulanması ile elde tahminlenen parseller ve bu parsellerin gerçek referansları görsel olarak Görsel 4.14’de sunulmuştur.



Görsel 4.14. Xgboost sınıflandırıcının *Pan-Keskinleştirme* test veri setine uygulanması ile tahmin edilen parsel sınıfları

4.2. Algoritmalarının Karşılaştırılması

Tez çalışması kapsamında üç farklı veri setine dört farklı makine öğrenmesi algoritması uygulanarak tarımsal bir sahada beş farklı ürünün haritalanması hedeflenmiştir. Makine öğrenmesi sürecinde eğitim sahası olarak belirlenen bir alanda ilgili veri setleri kullanılarak sınıflandırıcı modeller geliştirilmiş, bu modeller eğitim sürecine dahil edilmeyen başka bir test sahasında test edilmiştir. Bu bölümde elde edilen sonuçlar ürün bazlı ve genel doğruluk metriklerine göre karşılaştırılmıştır.

Algoritmaların ve farklı veri setlerinin domates ürünün tespit etmedeki başarısına ait özet kullanıcı doğrulukları ve üretici doğrulukları Tablo 4.13'te gösterilmiştir. Tablo irdelendiğinde, üretici doğrulukları tüm veri setlerinde ve algoritmalarda %70 doğruluk değeri altında kalmıştır. En iyi sonuç %66 ile DVM algoritmasının Pan-keskinleştirilmiş veri setine uygulanması ile elde edilmiştir. Bu değer kendisine en yakın olan DVM'nin Sentinel-2 veri setine uygulanması ile elde edilen %62'lik başarısından %4 fazladır. Diğer algoritmaların farklı veri setlerine uygulanmasında ise en az %10 üzerinde daha iyi sonuç verdiği görülmektedir. Domates bitkisinin bir önceki bölümde verilen hata matrislerinde en çok üzüm bitkisi ile karıştığı görülmektedir. Bu hatanın kaynağı ele alındığında domates bitkisi tarlalara sıralı şekilde ekilmekte bu sıralar arasında 1-1.5 m aralık bırakılmaktadır. Benzer şekilde üzüm asmaları da sıralı şekilde dikilmekte ve asma sıraları arasında toprak boşlukları oluşmaktadır. Bundan kaynaklı olarak uydu görüntülerinde kaydedilen değerler bitki ve toprak karışımına ait spektral yansımalar olmaktadır. Ayrıca Ek-1, Ek-6 ve Ek-11 verilen veri setlerinin tanımlayıcı istatistikleri incelendiğinde özellikle domates bitkisinin test verisine değerlerde bazı indeks ve bant değerlerinin üzüm eğitim verisi istatistiklerine yakın olduğu görülmektedir.

Tablo 4.13. Domates ürüne ait doğruluk metrikleri

Ürün	Yöntem	Veri	Üretici Doğ.	Kullanıcı Doğ.
Domates	RO	Sentinel-2	0,524	0,942
		Planet Scope	0,112	0,778
		Pan-Keskinleştirme	0,520	0,903
	DVM	Sentinel-2	0,616	0,865
		Planet Scope	0,096	0,857
		Pan-Keskinleştirme	0,664	0,888
	KNN	Sentinel-2	0,324	0,920
		Planet Scope	0,196	0,831
		Pan-Keskinleştirme	0,428	0,922
	XGBoost	Sentinel-2	0,528	0,930
		Planet Scope	0,136	0,850
		Pan-Keskinleştirme	0,560	0,940

Mısır bitkisine ait doğruluk metrikleri Tablo 4.14’de gösterilmiştir. Bitkinin farklı algoritmalar ve farklı veri setleri ile elde edilen sonuçları incelendiğinde gerek algoritma bazında gerekse veri seti bazında başarı oranların yüksek olduğu görülmektedir. Mısır bitkisinin en yüksek kullanıcı doğruluğu %93 ile DVM algoritmasının Pan-Keskinleştirme veri setine uygulanması ile elde edilmiştir. En yüksek üretici doğruluğu ise %89 ile XGBoost ve RO algoritmalarının Planet Scope veri setine uygulanması ile elde edilmiştir. Aynı algoritmaların aynı veri setine uygulanması ile en düşük kullanıcı doğrulukları olan %79 ve %77 elde edilmiştir. Kullanıcı doğruluklarının düşük olduğu alanlarda pamuk bitkisinin mısır olarak haritalandığı hata matrislerinden görülmektedir (Tablo 4.2 ve Tablo 4.11). Bu durumun sebebi Planet Scope verisi yakın kızıl ötesi bölgede tek bant içerdiğinden dolayı pamuk ve mısır arasındaki ayrımı çok başarılı şekilde yapamaması şeklinde yorumlanabilir ve Sentinel-2 verisinin spektral bantlarının ürün ayrımındaki üstünlüğünü gösterir. Diğer taraftan DVM algoritmasının az sayıda veri içeren Planet Scope verisinde kullanıcı doğruluğunu %85 olarak elde ettiği görülmektedir. Bu durumda DVM’nin az sayıda veri içeren veri setlerinde başarılı olduğunu gösterir.

Tablo 4.14. Mısır ürüne ait doğruluk metrikleri

Ürün	Yöntem	Veri	Üretici Doğ.	Kullanıcı Doğ.
Mısır	RO	Sentinel-2	0,874	0,914
		Planet Scope	0,890	0,786
		Pan-Keskinleştirme	0,873	0,912
	DVM	Sentinel-2	0,864	0,916
		Planet Scope	0,875	0,847
		Pan-Keskinleştirme	0,879	0,929
	KNN	Sentinel-2	0,873	0,918
		Planet Scope	0,881	0,813
		Pan-Keskinleştirme	0,864	0,935
	XGBOOST	Sentinel-2	0,874	0,928
		Planet Scope	0,894	0,773
		Pan-Keskinleştirme	0,882	0,908

Çalışma kapsamında haritalanan bir diğer ürün olan Pamuk ürününe ait doğruluk metrikleri Tablo 4.15’de gösterilmiştir. Tablo ele alındığında pamuk ürünü en yüksek kullanıcı doğruluğu (%89) ve üretici doğruluğu (%92) DVM algoritmasının Pan-keskinleştirme veri setine uygulanması ile elde edilmiştir. Planet Scope veri seti haricinde algoritmaların diğer veri setlerine uygulanmasında yüksek doğruluklarla Pamuk bitkisi tespit edilmiştir. Planet Scope veri verinde tüm algoritmaların üretici doğrulukları %70 altında, kullanıcı doğrulukları KNN algoritması hariç %80 altında kalmıştır. Pamuk

bitkisi Planet Scope veri setlerinde en çok Mısır verisi ile karışmıştır. Bu durum sınıflandırmada kullanılan değişkenlerin tanımlayıcı istatistikleri yakın olan ürünlerde (Ek-3, Ek-8 ve Ek-13) spektral bant çeşitliliğin doğruluğu yüksek oranda artırdığını göstermektedir. Gerek orijinal Sentinel-2 verisinde gerekse keskinleştirilmiş veride spektral bant sayısı ve bu bantlara ait indeks sayısının fazlalığı doğruluk değerini büyük ölçüde artırmıştır.

Tablo 4.15. Pamuk ürününe ait doğruluk metrikleri

Ürün	Yöntem	Veri	Üretici Doğ.	Kullanıcı Doğ.
Pamuk	RO	Sentinel-2	0,846	0,848
		Planet Scope	0,626	0,788
		Pan-Keskinleştirme	0,826	0,865
	DVM	Sentinel-2	0,871	0,917
		Planet Scope	0,657	0,799
		Pan-Keskinleştirme	0,888	0,921
	KNN	Sentinel-2	0,803	0,844
		Planet Scope	0,610	0,810
		Pan-Keskinleştirme	0,826	0,886
	XGBOOST	Sentinel-2	0,860	0,882
		Planet Scope	0,581	0,799
		Pan-Keskinleştirme	0,846	0,888

Çalışmada tespit işlemi gerçekleştirilen bir diğer ürün olan üzüm bitkisine ait doğruluk metrikleri Tablo 4.16’da gösterilmiştir. Tablo incelendiğinde üzüm bitkisinin tespitinde en iyi sonuçlar %94 üretici doğruluğu ve %78 kullanıcı doğruluğu ile DVM algoritmasının Pan-keskinleştirilmiş görüntüye uygulanması ile elde edilmiştir. Dört algoritmanın üç farklı veri setine uygulanması ile elde edilen üretici doğrulukları %85’in üzerinde elde edilmiştir. Bu durum tüm algoritmaların test sahasında gerçekte üzüm olan parselleri yüksek doğrulukla tespit ettiğini göstermektedir. Diğer taraftan tüm algoritmaların tüm veri setlerindeki kullanıcı doğrulukları %80 altında elde edilmiştir. Bu durum gerçekte üzüm olmayan parsellerin üzüm olarak tespit edildiğini göstermektedir. Bölüm 4.1 altında verilen hata matrisleri incelendiğinde domates parsellerinin birçok algoritma ve veri setinde üzüm olarak haritalandığı görülmektedir. Bu durumun temel nedenlerinden birincisi domates ve üzüm bitkisinin sıralı şekilde ekilmesi ve piksellerde toprak bitki karışımı heterojen bir yapının söz konusu olması, diğeri ise test sahasındaki veri setlerindeki bazı domates değişkenlerinin eğitim sahasındaki üzüm değişkenleri ile yakın değerlere sahip olması şeklinde açıklanabilir (Ek-4, Ek-9 ve Ek-14).

Tablo 4.16. Üzüm ürününe ait doğruluk metrikleri

Ürün	Yöntem	Veri	Üretici Doğ.	Kullanıcı Doğ.
Üzüm	RO	Sentinel-2	0,938	0,728
		Planet Scope	0,852	0,647
		Pan-Keskinleştirme	0,926	0,722
	DVM	Sentinel-2	0,925	0,754
		Planet Scope	0,903	0,619
		Pan-Keskinleştirme	0,940	0,779
	KNN	Sentinel-2	0,924	0,674
		Planet Scope	0,916	0,657
		Pan-Keskinleştirme	0,932	0,673
	XGBOOST	Sentinel-2	0,951	0,723
		Planet Scope	0,877	0,650
		Pan-Keskinleştirme	0,930	0,748

Çalışma kapsamında tespit edilmeye çalışılan beşinci ürün olan Zeytine ait doğruluk metrikleri Tablo 4.17’de gösterilmiştir. En yüksek üretici doğruluğu %93 ile DVM algoritmasının Planet Scope verisine uygulanması ile elde edilirken, en yüksek kullanıcı doğruluğu %85 ile XGBoost algoritmasının Sentinel-2 verisine uygulanması ile elde edilmiştir. Genel olarak üretici doğrulukları tüm algoritma ve veri setlerinde %83 üzerinden elde edilmiştir. Kullanıcı doğrulukları üretici doğruluklarına göre daha düşük seviyede kalmıştır. Bölüm 4.1’de verilen hata matrisleri incelendiğinde zeytin alanı olarak çıkarılan hatalı parseller genel olarak üzüm ve domates parsellerdir. Bu ürünlerde olduğu gibi zeytin ağaçları aralıklı olarak dikilmektedir. Dolayısı ile tarım parsellerinde toprak ve bitki karışımı olan heterojen veri olabilmektedir. Bu durumda sınıfların karışmasına sebep olmaktadır.

Tablo 4.17. Zeytin ürününe ait doğruluk metrikleri

Ürün	Yöntem	Veri	Üretici Doğ.	Kullanıcı Doğ.
Zeytin	RO	Sentinel-2	0,869	0,845
		Planet Scope	0,909	0,769
		Pan-Keskinleştirme	0,892	0,813
	DVM	Sentinel-2	0,831	0,726
		Planet Scope	0,926	0,773
		Pan-Keskinleştirme	0,898	0,823
	KNN	Sentinel-2	0,909	0,755
		Planet Scope	0,875	0,774
		Pan-Keskinleştirme	0,898	0,771
	XGBOOST	Sentinel-2	0,892	0,849
		Planet Scope	0,886	0,808
		Pan-Keskinleştirme	0,920	0,822

Çalışmada uygulanan makine öğrenme algoritmalarının veri setleri üzerindeki genel doğruluk ve Kappa değerleri özet olarak Tablo 4.18 ve Tablo 4.19’da gösterilmiştir.

Bu değerlere göre en yüksek genel doğruluk ve Kappa değeri DVM algoritmasının Pan-keskinleştirilmiş veri setine uygulanması ile elde edilmiştir. KNN algoritması diğer algoritmalarla kıyaslandığında en düşük genel doğruluk ve Kappa değerlerini vermiştir. Kullanılan dört farklı makine öğrenme algoritmasının Planet Scope veri seti üzerindeki başarıları oldukça düşük olarak karşımıza çıkmaktadır. Kappa değerleri 0.70 altında elde edilirken, genel doğruluk değerleri %73-%76 arasında elde edilmiştir. Bu sonuçlar yakın kıvılcık bölgesinde sadece NIR bandı olan Planet Scope görüntüsünün tarım alanlarını tespit etmede Sentinel-2 verisine göre daha başarısız olduğunu göstermektedir.

Tablo 4.18. Tüm görüntü ve tüm algoritma sonuçlarını içeren genel doğruluk sonuç tablosu

	Genel Doğruluk		
	SENTİNEL-2	PLANET SCOPE	PAN DATA
Rastgele Orman	84,11%	73,32%	83,57%
Destek Vektör Makinaları	84,65%	75,28%	87,05%
En Yakın Komşuluk	80,87%	75,72%	82,30%
XGBoost	84,89%	74,15%	85,09%

Sentinel-2 veri setlerinde genel olarak tüm algoritmalar %80 üzerinde genel doğruluk verirken, Kappa değeri KNN’de 0.74 diğer algoritmalarda 0.79 olarak elde edilmiştir. Pan-keskinleştirilmiş görüntüye algoritmaların uygulanmasında Rastgele Orman algoritması dışında diğer algoritmalarda hem genel doğruluk hem de Kappa değeri artmıştır. Bu sonuçlar bize Sentinel-2 verisi ve Planet Scope verisinin füzyonunun sınıflandırmaya olumlu şekilde etkisinin olduğunu göstermektedir.

Tablo 4.19. Tüm görüntü ve tüm algoritma sonuçlarını içeren kappa sonuç tablosu

	Kappa Katsayısı		
	SENTİNEL-2	PLANET SCOPE	PAN DATA
Rastgele Orman	0,79	0,63	0,78
Destek Vektör Makinaları	0,79	0,63	0,82
En Yakın Komşuluk	0,74	0,67	0,76
XGBoost	0,79	0,64	0,80

5. ARAŞTIRMA SONUÇLARI

Bu çalışmada gıda güvenliği ve sürdürülebilir tarım politikaları kapsamında Manisa il sınırlarında belirlenen bir çalışma sahasında uydu görüntüleri ve makine öğrenme algoritmaları ile tarımsal ürünlerin tespit edilmesi işlemi gerçekleştirilmiştir. Çalışma süresince öncelikle tarım parselleri ve bu parsellerde yetiştirilen ürünler ilgili kurum ve kuruluşlardan temin edilmiştir. Elde edilen parselleri analize hazır hale getirmek için parseller üzerinde düzenleme yapılmıştır. Farklı uydu görüntülerinin ürün tespitindeki başarısının araştırılması için Sentinel-2 ve PlanetScope verilerinden faydalanılmıştır. Bu uydulara ait bantların füzyonu ile Pan-keskinleştirilmiş bir görüntü seti de üretilerek çalışma zenginleştirilmiştir. Parseller, parsellere ait bant ve bant indeksleri ile eğitim ve test sahası olarak ayrılan çalışma sahasında üç farklı veri setine dört farklı makine öğrenme algoritması uygulanarak ürün tespitinde uydu görüntüsü ve algoritma performansları araştırılmıştır. Bu kapsamda tez sürecinde yapılan işlemler ve elde edilen sonuçlara aşağıdaki şekildedir.

5.1. Parsel Bazlı Ürün Tespiti

Uzaktan algılama yöntemleri ile yapılan araştırmalarda, doğrudan uydu görüntüleri üzerinden piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımları ile tarım parselleri ya da tarımsal alanların tespiti gerçekleştirilebilmektedir. Bu çalışmalarda özellikle ürün tespitinde tarım parseli dışındaki arazi detaylarının da ayırt edilmeye çalışılması ürünlerin yeşil alanlar ve diğer tarımsal alana benzer özellik gösteren alanlarla karışmasına neden olmaktadır. Bu çalışmada tarım parselleri birer nesne kabul edilerek parsel tabanlı ürün tespiti yapılmıştır. Bu sayede çalışmanın odak noktası halihazırda ilgili kurumlarda bulunan parsel sınırları ile sınırlandırılmış ve tarım alanı dışındaki arazi kullanım özelliklerinden kaynaklı ortaya çıkabilecek hatalar minimize edilmiştir.

Gerek Türkiye’de gerekse dünyanın birçok ülkesinde tarımsal üretime ait parseller veritabanlarında saklanmaktadır. Bu parseller üzerinde saha kontrolleri ya da çiftçi beyanlarına esas olarak ürün bilgileri parsellere işlenmekte ve bu bilgiler doğrultusunda tarımsal üretim destek ödemeleri, rekolte tahminleri, su kaynağı aktarımı, ithalat veya ihracat kararları tarım politikaları kapsamında karara bağlanmaktadır. Sürdürülebilir tarım politikaları ve gıda güvenliği bağlamında çiftçi beyanları yanıltıcı olabilmektedir. Saha tespitine bağlı ürün tespiti ise personel, zaman ve maliyet açısından kısıtlamalar

oluşturmaktadır. Bundan dolayı uydu görüntülerine bağlı çözümlerin geliştirilmesi gerek sürdürülebilirlik gerek tarım politikalarının geliştirilmesi gerekse gıda güvenliği açısından son derece önem arz etmektedir.

5.2. Sınıflandırma Algoritmaları ve Veri Setleri

Tez çalışmasında araştırma sahası olarak seçilen tarımsal alanda Planet Scope, Sentinel-2 ve Pan-keskinleştirilmiş görüntü olmak üzere üç farklı görüntüden üretilen veri setlerine RO, DVM, KNN ve XGBOOST (XGB) algoritmaları uygulanmıştır. Eğitim sahası olarak belirlenen alanda sınıflandırıcı modeller geliştirilmiş, test sahası olarak belirlenen alanda model performansları test edilmiştir. Bu şekilde tez çalışmasında toplamda 12 adet sınıflandırıcı model geliştirilmiştir. Her bir modelin test sahasına göre doğruluk analizleri yapılmıştır. Elde edilen sonuçlar dördüncü bölümde değerlendirilmiştir. Bu bölümde geliştirilen modellerin başarısının istatistiksel olarak anlamlı olup olmadığı incelenmiştir. Bu doğrultuda sınıflandırıcı modellerin performansları ikili karşılaştırma ile Mcnemar testine tabi tutularak istatistiksel anlamlılıkları araştırılmıştır. Bu değerler Tablo 5.1’de gösterilmiştir. Tabloda yapılan karşılaştırmada istatistiksel olarak anlamlı olmayan sonuçlar koyu siyah renkli olarak işaretlenmiştir. Ayrıca, her bir ikili karşılaştırmaya ait Ki-Kare ve p değerleri ayrı ayrı gösterilmiştir. Tüm karşılaştırmalarda serbestlik derecesi 1, $\chi^2 = 3.481$ ve p değeri referans sınırı 0.05 olarak ele alınmıştır.

Yapılan analizlerde Sentinel-2 ve Pan-keskinleştirme veri setleri ile yapılan ürün tespit işlemi daha yüksek doğruluk değerleri vermektedir (Tablo 4.18 ve Tablo 4.19). Bu değerlerin istatistiksel olarak anlamlılıkları bakıldığında $\chi^2 = 3.841$, serbestlik derecesi 1 ve $p = 0.05$ anlamlılık seviyesinde Sentinel-2 ve Pan-Keskinleştirme ile elde edilen yüksek doğruluk değerlerinin istatistiksel olarak anlamlı olduğu görülmektedir. Çünkü Sentinel-2 ve Pan-keskinleştirme için dört algoritma ile geliştirilen model sonuçları Planet Scope veri seti sonuçları ile karşılaştırıldığında χ^2 değeri 3.841’den büyük, p değeri 0.05’den küçük değerler olarak elde edilmiştir (Tablo 5.1).

Planet Scope veri seti algoritma bazında el alındığında, KNN algoritmasının vermiş olduğu yüksek doğruluk değeri RO ve XGB algoritmalarına göre istatistiksel olarak anlamlı, DVM algoritmasına göre anlamsızdır. DVM algoritmasının performansı RO algoritmasına göre istatistiksel olarak anlamlı iken, XGB algoritmasına göre anlamsızdır. Anlamsız olan durumlarda her iki algoritma aynı parselde doğru tahminleme yaparken,

aynı parsellerde yanlış tahminleme yapmıştır. Bu sonuçlar bize az değişken içeren veri setlerinde KNN algoritmasının iyi sonuçlar vereceğini göstermektedir.

Sentinel 2 veri setinde algoritma performansı en düşük olan KNN algoritmasıdır. Diğer algoritmaların bu veri setinde KNN göre elde ettikleri yüksek doğruluk değerleri istatistiksel olarak anlamlıdır. Diğer taraftan RO, DVM ve XGB algoritmaları ile Sentinel-2 verisinde elde edilen sonuçlar istatistiksel olarak anlamsızdır (Tablo 5.1).

KNN algoritması tüm sınıflandırma algoritmaları içinde PlanetScope veri seti hariç en düşük sonucu veren algoritmadır. Sentinel-2 ve Pan-keskinleştirilmiş veri setlerinde diğer üç algoritma ile elde edilen sonuçlar KNN algoritması ile elde edilen sonuçlara göre istatistiksel olarak anlamlıdır. Bu sonuç bize veri seti içindeki değişken sayısı arttıkça KNN algoritmasının performansının düştüğünü göstermektedir.

Ağaç tabanlı çalışan RO ve XGB algoritmalarının aynı veri setlerindeki başarısı ele alındığında PlanetScope ve Sentinel-2 veri setlerinde algoritmaların sonuçları istatistiksel olarak anlamsızdır, başka bir ifade ile iki algoritmanın bu veri setlerinde birbirlerine karşı bir üstünlüğü yoktur. Pan-keskinleştirme veri setinde ise XGB algoritması ile daha yüksek sonuçlar elde edilmiştir ve bu sonuçlar istatistiksel olarak anlamlıdır (Tablo 5.1).

Çalışma kapsamında Sentinel-2 ve Pan-keskinleştirilmiş görüntü setlerinde aynı indeksler ve bantlar kullanılmıştır. Bu veri setlerine aynı algoritmaların uygulanmasında RO algoritması dışında diğer algoritmalarda genel doğruluk ve Kappa değerleri artış göstermiştir. KNN ve DVM algoritmaları ile her iki veri setinden elde edilen sonuçlar istatistiksel olarak anlamlıdır. RO ve XGB ile elde edilen farklar, istatistiksel olarak anlamsızdır. Çalışmada en yüksek doğruluk DVM algoritmasının Pan-keskinleştirme verisine uygulanması ile elde edilmiştir. Bu sınıflandırıcı modelin performansı diğer 11 model ile karşılaştırıldığında elde edilen performans artışı hepsinde istatistiksel olarak anlamlıdır. Bu durum bize görüntü füzyonunun tarımsal parsellerin tespitinde başarıyı artırdığını göstermektedir.

Tablo 5.1. Üç farklı veri setine uygulanan dört makine öğrenme algoritması için geliştirilen sınıflandırıcı modellerin McNemar testi sonuçları

Ki-Kar+B2:M26e (γ2) Değerleri Tablosu											
	PS_RO	PS_XGB	PS_DVM	S2_KNN	S2_RO	S2_XGB	S2_DVM	PAN_KNN	PAN_RO	PAN_XGB	PAN_DVM
PS_KNN	91.413	60.114	0.095745	59.405	115.13	143.63	144.03	88.533	105.47	146.25	180.97
PS_RO		0.3125	66.489	87.823	145.92	171.98	172.19	112.46	134.9	182.1	205.8
PS_XGB			34.057	78.27	137.5	165.09	163.13	100.47	126.68	168.88	195.57
PS_DVM				66.505	122.29	152.1	154.69	92.042	117.11	153.49	185.92
S2_KNN					31.53	51.258	60.208	79.239	19.57	50.88	87.615
S2_RO						38.793	Mar.61	12.009	15.873	44.024	31.769
S2_XGB							0.10227	28.Eyl	8.557	0.10976	18.Nis
S2_DVM								29.009	85.714	0	18.186
PAN_KNN									58.783	25.786	68.966
PAN_RO										12.676	44.408
PAN_XGB											15.339
p Değerleri tablosu											
	PS_RO	PS_XGB	PS_DVM	S2_KNN	S2_RO	S2_XGB	S2_DVM	PAN_KNN	PAN_RO	PAN_XGB	PAN_DVM
PS_KNN	0.002499	0.01421	0.757	1.28 e ⁻¹⁴	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶
PS_RO		0.5762	0.009922	2.2 e ⁻¹⁶	2.2 E ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶
PS_XGB			0.06497	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶
PS_DVM				2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶	2.2 e ⁻¹⁶
S2_KNN					1.96 e ⁻⁸	8.10 e ⁻¹³	8.53 e ⁻¹⁵	0.004879	9.70 e ⁻⁶	9.82 e ⁻⁶	2.2 e ⁻¹⁶
S2_RO						0.04888	0.05743	0.0005295	0.2077	0.03589	1.74 e ⁻⁸
S2_XGB							0.7491	1.16 e ⁻⁷	0.003442	0.7404	1.79 e ⁻⁵
S2_DVM								7.21 e ⁻⁸	0.003415	1	2.00 e ⁻⁵
PAN_KNN									0.01533	3.82 e ⁻⁷	2.20 e ⁻¹⁶
PAN_RO										0.0003704	2.67 e ⁻¹¹
PAN_XGB											8.98 e ⁻⁵

Çalışma kapsamında elde edilen sonuçlar veri seti bazında değerlendirildiğinde Sentinel-2 verileri ile ürün tespiti işlemi PlanetScope verilerine göre daha yüksek doğrulukta ve istatistiksel olarak anlamlı seviyede gerçekleşmiştir. Bu sonuçlar parsel tabanlı sınıflandırma işleminde mekânsal çözünürlükten ziyade spektral çözünürlüğün fazla olmasının ürün tespitindeki başarıyı artırdığını göstermektedir.

Tez araştırmasında Sentinel-2 ve PlanetScope görüntülerinin füzyonu ile oluşturulan Pan-keskinleştirilmiş görüntüden elde edilen veri setlerinde RO algoritması haricinde diğer algoritmalarda doğruluk değeri artmıştır. Özellikle DVM algoritmasının Pan-keskinleştirme veri setine uygulanmasında %85 genel doğruluk ve 0.83 Kappa istatistiği elde edilmiştir. Bu sonuçlar diğer sınıflandırıcı modellerle karşılaştırıldığında istatistiksel olarak anlamlıdır. Doğruluk değerlerindeki artış incelendiğinde özellikle domates ürününün tahminlemesinde başarı %67'ye kadar artmıştır. Genel olarak domates bitkisi üzüm bitkisi ile araştırmada sıklıkla karıştığı gözlemlenmiştir. Pan-keskinleştirilmiş görüntüde Planet Scope ile mekânsal çözünürlük 3 m olarak artırılmış, spektral çözünürlük ise Sentinel-2 görüntüsü ile zenginleştirilmiştir. Bu sayede özellikle domates parsellerinde görüntü füzyonu domates alanlarını üzüm alanlarında ayırt edilme başarısını artırmıştır.

5.3. Gıda Güvenliği Açısından Tarımsal Ürün Tespiti

Gıda güvenliği konusu farklı disiplinlerin çalıştığı geniş bir zincirdir. UA ve CBS teknolojileri, yönetilmesi zor çok parametrelili bu konunun bir soruna dönüşmesini engelleyebilecek, zincirin hemen tüm halkalarına ulaşan bir disiplindir. Gıda güvenliğinde en temel öğelerden birisi gıdanın miktarının tespit edilmesi, yönetilmesi, geleceği yönelik planlanmaların yapılması ve tedarik zincirlerinin oluşturulmasıdır. Tarımsal üretimde en temel işlemi tarım parsellerindeki bilgilerin doğru olarak tutulması ve gıda güvenliği zincirine dahil edilmesidir. Bu kapsamda yapılan bu çalışma gıda güvenliğine yönelik ürün tespiti ve yönetimi açısından faydalıdır.

Gıda güvenliğine yönelik tarım parsellerinin yönetiminde tarım alanları ile yapılacak hemen her çalışmanın altlığı olan çiftçi beyanları ve tarım parselleri verilerinde karşılaşılabilecek birçok sorunun tespiti ve çözümüne ışık tutulmuştur. Bu sorunların çözümleri ilgili öneriler sunulmuştur.

6. TARTIŞMA VE ÖNERİLER

Bu çalışmada tarım parsel sınırları ve ürün bilgileri CBS ve UA uygulamalarına entegre edilebilir formatta düzenlenmiş; dört farklı algoritma, iki farklı uydu görüntüsü ve bu görüntülerin füzyonundan oluşan üçüncü bir görüntü kullanılarak sınıflandırma işlemi yapılmıştır. Bu süreçte karşılaşılan hatalara yönelik çözüm önerileri, çalışma kapsamında elde edilen deneyimler ve bu deneyimlere dayanarak literatüre kazandırılmasında fayda görülen çalışma önerileri bu bölümde özetlenmiştir.

Referans alınan tarım parsellerindeki en büyük problemlerden birisi aynı ekim-hayat döneminde bir tarım parseli içinde birden çok ürün yetiştirilmesidir. Analiz işlemine dahil edilecek parseller incelendiğinde bir parsel içinde birden çok ürün bulunmaktadır. Bu ürünler parsel veri tabanında ürün sınırları ve alanları belli olmadan parselin tamamı ile ilişkilendirilerek tutulmaktadır. Örneğin gerçekte bir parselin üçte birinde mısır, üçte birinde üzüm, üçte birinde domates yetiştirilirken veri tabanına sadece ilgili parselde domates, mısır ve üzüm girdileri yapılmaktadır. Bu veri tabanında sadece mısır yetiştirilen parseller hangileridir ve alanları nedir gibi bir sorgulama yapıldığında gerçekte olmayan alan bilgileri elde edilecektir. Buna bağlı yapılacak tahminleme ya da geliştirilecek tarım politikaları hatalı sonuçlar ortaya çıkaracaktır. Bu problemin önüne geçilmesi için öncelikle bir tarım parselinde aynı dönemde birden çok ürün yetiştiriliyorsa, bu parselin ilgili ürünlerin yetiştirildiği sınırlara göre geçici bir bölünme yöntemine göre yıllık bölünmesi yapılmalıdır. Bu bölme işlemi araziden yerinde tespit ile yapılabileceği gibi uzaktan algılama destekli de gerçekleştirilebilir. Uzaktan algılama destekli yıllık geçici parsel bölümle görsel yorumlama ile manuel bölme ya da görüntü analizleri otomatik bölme şeklinde yapılabilir. Görsel yorumlama ile yapılacak çalışmalarda tarımsal alanlara ait yüksek mekânsal çözünürlüklü uydu görüntüleri temin edilerek ürünler görsel yorumlama ile tespit edilip parsel bölümlenmeleri manuel çizilebilir. Otomatik geçici parsel bölmede ise yüksek mekânsal çözünürlük görüntüler temin edildikten sonra her bir ana parsel içinde otomatik ürün çeşitlerini arama, tespit etme ve sınır çizme algoritmaları geliştirilmelidir. Bu algoritmalar ile parsel geçici bölmelerine ayrılmalıdır.

Çalışma kapsamında kullanılan parsellerde tespit edilen hatalardan bir diğeri parsel içinde bina, farklı yapı ya da seraların bulunmasıdır. Bu durumda da geliştirilecek tarımsal politikalarda hatalara ortaya çıkacaktır. Bu durumun önüne geçilmesi için her bir parselin ekili alanı ve ekili olmayan bölgeleri tespit edilmelidir. Bu süreçte bir önceki

paragrafta belirtildiği gibi otomatik olarak yönetilebilir. Benzer şekilde büyük bir parselin küçük bir bölümüne ürün ekili olabilmekte, büyük bir bölümü nadasa bırakılabilmektedir. Ancak veritabanında ekili ürün kısmında herhangi bir sınır ayrımı olmadan ilgili ürün bilgisi girilmektedir. Bu durum da gıda güvenliği ve sürdürülebilirlik açısından sakıncalı bir durumdur. Bundan dolayı da parsellerin ekili ve ekili olmayan sınırlarını otomatik tespit edecek algoritmaların geliştirilmesine ihtiyaç vardır. Günümüzdeki uydu teknolojileri, insansız hava aracı teknolojileri ve yapay zekâ algoritmalarındaki gelişmelerle bunların yapılması mümkündür.

Çalışma kapsamında tespit edilen bir başka problem parsellerin veritabanına girilen ürünlerle, arazideki karşılıklarının örtüşmemesidir. Bu problem genel olarak çiftçi beyanının esas alındığı durumlarda ortaya çıkmaktadır. Bu durumun önüne geçilmesi için yerinde tespit, uydu görüntüleri ile kontrol ve parsel bazlı otomatik ürün tespiti algoritmalarının geliştirilmesi son derece önemlidir.

Çalışma kapsamında düzenlenmesi gerçekleştirilen parsel sınırları üzerinden ürün tespiti yapılmıştır. Halihazırda var olan parsel sınırlarına bağlı olarak gerçekleştirilen ürün tespiti işlemleri doğrudan parsellere odaklanmakta ve parsel haricindeki hata kaynaklarının önüne geçmektedir. Ülkemizde ve dünya genelinde tarım sektörünü yöneten devlet kurumları bu parsel bilgilerinin tutulmasını ve yönetilmesini sağlamaktadır. Gelecekte tarım politikaları, gıda güvenliği ve sürdürülebilir tarım uygulamaları açısından tarım parsel sınırları ve bu parsellerde yetişen ürünlerin tutarlılığın sağlanması son derece önemlidir. Parsel bazlı yapılan tespitler ise doğrudan parsellere odaklandığından daha gerçekçi sonuçların elde edilmesi açısından kapsamında önerilmektedir.

Araştırma kapsamında eğitim ve test alanları farklı sahalar olarak seçilmiştir. Bu seçimdeki amaç mekânsal olarak eğitime dahil edilmeyen bir alanda geliştirilen modellerin başarısının tespit etmek ve modellerin farklı alanlara transferinin mümkün olup olmadığını anlamaktır. Genel olarak geliştirilen modeller mısır, pamuk, üzüm ve zeytin ürünlerinin tespitinde yüksek doğruluklar vermiştir. Ancak domates parselleri üzüm parsellerinden ayırt edilmesi istenilen seviyede gerçekleştirilmemiştir. Bu doğrultuda eğitim ve test alanların mekânsal olarak aynı bölge içinde rastgele seçilmesi ile bu başarının artıp artmayacağı gelecekte test edilmesi ürün tespit modellerinin geliştirilmesi açısından anlamlı olacaktır.

Araştırmada görüntü füzyonunun tarım parsellerini tespit etmede olumlu sonuçlar verdiği gözlemlenmiştir. Görüntü füzyonu alanı her gün yeni yöntemlerin geliştirildiği geniş bir alandır. Bu çalışmada X + PS yöntemi kullanılarak görüntü füzyonu gerçekleştirilmiştir. Literatürde kullanılan diğer yöntemlerinde tarımsal ürün tespitindeki başarıları mutlaka araştırılmadığıdır. Ayrıca günümüzde PlanetScope uydularının 8 bantlı görüntüleri kullanıma sunulmuştur. Yeni kullanıma açılan diğer bantlarında özellikle tarımsal ürün tespitindeki başarısının araştırılması önerilmektedir.

Tez çalışmasında özellikle tarımsal parsellerin temini bu parseller içinden uygun ürünlerin belirlenmesi ve uygun görüntü kümesinin seçimi gibi kısıtlamalardan dolayı sadece mısır, pamuk, üzüm, domates ve zeytin gibi tarımsal ürünlere yönelik sınıflandırma işlemi gerçekleştirilmiştir. Bu tez çalışmasında ürün seçimindeki en önemli etken verinin varlığı olmuştur. Veriye erişim, bu verilerin optimum seviyede organize edilmesi ve kullanılabilir hale getirilmesi oldukça zaman isteyen bir organizasyon süreci gerektirmektedir. Gelecekte yapılacak çalışmalarda ürün sayıları artırılmalıdır. Ya da her ürüne özel bir tespit modeli geliştirilmelidir. Her iki durumda da veriyi yöneten kurumlar ve bu veri üzerinden bilimsel araştırmalar yaparak yeni sistemleri geliştirecek üniversiteler arasındaki koordinasyon sürdürülebilir şekilde iyileştirilmelidir. Özellikle veri yönetimi aşamasında CBS teknolojilerinin en optimum şekilde yararlanılırken, uzaktan algılamanın getirdiği yenilikler güncel olarak geliştirilecek sistemlere dahil edilmelidir.

Ekili alanların dinamik bir veri olması, senede iki veya üç sefer değişiklik gösterilmesinden dolayı tarım alanı dışındaki arazi kullanım özelliklerinden kaynaklı hataların minimize edilebileceği ve daha sürdürülebilir bir yaklaşım olan parsel bazlı ürün tespitinin gelecek çalışmalarda da uygulanması önerilmektedir. Bunların yanında özellikle gıda güvenliği zincirinin en önemli halkalarından birisi olan tüm tarım alanlarının vektörel olarak tespit edilmesi ve bu dinamik verilerin her sezon güncellenmesi bu güncelleme işlemleri için ilgili kurumların taşra teşkilatlarına gerekli birimlerin kurulması ve uzman personellerin istihdam edilmesi önerilmektedir. Beyana dayalı kayıt sisteminden edinilen verilerin arazi çalışmalarıyla kontrol edilmesi için daha kısa sürede (bir ekim hasat dönemi içerisinde) tamamlanabilecek çalışmaların yapılması ve ürünlerin arazi çalışmasıyla kontrol edilmesi önerilmektedir. Arazi çalışmalarında daha hızlı, ekonomik ve güncel veriler toplanması için insansız hava aracı tabanlı verilerin kontrol sistemlerine entegrasyonu önerilmektedir. Ayrıca vektör verilerin

kontrolü sırasında yüksek çözünürlüklü uydu görüntülerine ihtiyaç duyulmaktadır. Yerli uydularımız olan İmece ve Göktürk-1/Göktürk-2'den üretilen görüntüler manuel kontrol için kullanılabilir. Daha yüksek mekânsal çözünürlüklü olarak kullanılan PlanetScope görüntüsü yerine yerli uydularımızdan üretilen görüntüler kullanılabilir ve Sentinel-2 ile Göktürk-2 görüntüleri başka bir çalışmada füzyon edilebilir.



KAYNAKÇA

- Aguilera, M. A. Z. (2020). Classification of Land-Cover through Machine Learning Algorithms for Fusion of Sentinel-2a and PlanetScope Imagery. 2020 IEEE Latin American GRSS and ISPRS Remote Sensing Conference, LAGIRS 2020-Proceedings, 246–253.
- Anand, A. (2017). Unit-14 Accuracy Assessment.
- Ballester, C., Caselles, V., Igual, L., Verdera, J., & Rougé, B. (2006). A variational model for P+XS image fusion. *International Journal of Computer Vision*, 69(1), 43–58.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2–16.
- Breiman, L. (2001). Random forests. *Machine Learning* 45, 5–12.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System.
- Chih, W., Chih-Chung, C., & Chih-Jen, L. (2003). A practical guide to support vector classification.
- Colvocoresses, A. P. (1977). Proposed parameters for an operational landsat. In *Photogrammetric Engineering and Remote Sensing* 43.9, 1139–1145.
- Daughtry, C. S. T., Walthall, C. L., Kim, M. S., De Colstoun, & McMurtrey, J. E. (2000). Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote Sensing of Environment*, 229–239.
- Dizdaroğlu, T. (2019). Sentinel-1 ve Sentinel-2 Verilerinden Tarımsal Ürün Sınıflandırması İçin Makine Öğrenme Algoritmalarının Karşılaştırılması. Hacettepe Üniversitesi.
- Esemen, K. (2011). Uydu Görüntüleri ile Orman Yangını Analizi. Bilişim Enstitüsü.
- Gašparović, M., & Jogun, T. (2018). The effect of fusing Sentinel-2 bands on land-cover classification. *International Journal of Remote Sensing*, 39(3), 822–841.
- Gašparović, M., Jogun, T., Rao, P., Zhou, W., Bhattarai, N., Srivastava, A. K., Singh, B., Poonia, S., Lobell, D. B., Jain, M., Gašparović, M., Medak, D., Pilaš, I., Jurjević, L., Balenović, I., Shendryk, Y., Rist, Y., Ticehurst, C., Thorburn, P., ... Gachoki, S. (2018). Fusion of sentinel-2 and planetscope imagery for vegetation detection and monitoring. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences- ISPRS Archives*, 42(1), 155–160. <https://doi.org/10.5194/isprs-archives-XLII-1-155-2018>
- Huete, A. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*. [https://sci-hub.se/10.1016/0034-4257\(88\)90106-x](https://sci-hub.se/10.1016/0034-4257(88)90106-x)
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 195–213.
- Hunt, E. R., Daughtry, C. S. T., Eitel, J. U. H., & Long, D. S. (2011). Remote sensing leaf chlorophyll content using a visible Band index. *Agronomy Journal*, 1090–1099.

- Kaplan, G. (2020). Assessing the effectiveness of PlanetScope synthesized panchromatic bands for spatial enhancement of Sentinel-2 data. *Journal of Applied Remote Sensing*, 14(03), 1. <https://doi.org/10.1117/1.jrs.14.036504>
- Karadağ, K., & Taşalın, R. (2016). Biber Bitkisinden Alınan Spektral Yansımaların Yapay Sinir Ağları Kullanarak Hastalık Tespiti. In Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi (pp. 50–59).
- Kavak, Ş. (1998). Uzaktan algılamanın temel kavramları ve jeolojideki uygulama alanları. In *Jeoloji Mühendisliği Dergisi* (pp. 50–55).
- Kobayashi, N., Tani, H., Wang, X., & Sonobe, R. (2019). Crop classification using spectral indices derived from Sentinel-2A imagery. *Remote Sensing*, 11(1), 67–90. <https://doi.org/10.1080/24751839.2019.1694765>
- Kpienbaareh, D., Sun, X., Wang, J., Luginaah, I., Kerr, R. B., Lupafya, E., & Dakishoni, L. (2021). Crop type and land cover mapping in northern malawi using the integration of sentinel-1, sentinel-2, and planetscope satellite data. *Remote Sensing*, 13(4), 1–21. <https://doi.org/10.3390/RS13040700>
- Kursa, M. B., & Witold, R. Rudnicki. (2010). Feature selection with the Boruta package. *Journal of Statistical Software* 36, 1–13.
- Li, W., Jiang, J., Guo, T., Zhou, M., Tang, Y., Wang, Y., Zhang, Y., Cheng, T., Zhu, Y., Cao, W., & Yao, X. (2019). Generating red-edge images at 3M spatial resolution by fusing sentinel-2 and planet satellite products. *Remote Sensing*, 11(12). <https://doi.org/10.3390/rs11121422>
- Li, Z., Zhang, H. K., Roy, D. P., Yan, L., & Huang, H. (2020). Sharpening the Sentinel-2 10 and 20 m bands to planetscope-0 3 m resolution. *Remote Sensing*, 12(15), 2406. <https://doi.org/10.3390/RS12152406>
- Yılmaz, M. (2018). Tarımsal Yaz Ürünlerin Sentinel-2 Uydu Görüntülerinden Rastgele Orman Algoritması ile Nesne-Tabanlı Sınıflandırılması.
- Miura, T., Huete, A. R., Van Leeuwen, W. J. D., & Didan, K. (1998). Egetation detection through smoke-filled AVIRIS images: An assessment using MODIS band passes. In *Journal of Geophysical Research: Atmospheres* 103.D24 (pp. 32001–32011).
- Mudereri, B., Mudereri, B. T., Dube, T., Adel-Rahman, E. M., Niassy, S., Kimathi, E., Khan, Z., & Landmann, T. (2019). A comparative analysis of PlanetScope and Sentinel-2 space-borne sensors in mapping Striga weed using Guided Regularised Random Forest classification ensemble Bioresource mapping in the microsensor age View project Fungal Entomopathogens for Aphid Managem. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-701-2019>
- Myint, S. W., et al. (2011). Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment*, 1145–1161.
- Navulur, K. (2006). Multispectral image analysis using the object-oriented paradigm.
- Ömerci C. (1987). *Uzaktan Algılama (Temel Esaslar ve Algılama Sistemleri)*. İstanbul Teknik Üniversitesi.

- Özkan. (1988). Uzaktan algılama verileriyle orman yangını analizi. İstanbul Teknik Üniversitesi.
- Rao, P., Zhou, W., Bhattarai, N., Srivastava, A. K., Singh, B., Poonia, S., Lobell, D. B., & Jain, M. (2021). Using Sentinel-1, Sentinel-2, and Planet Imagery to Map Crop Type of Smallholder Farms. *Remote Sensing*, 13(10), 1870. <https://doi.org/10.3390/rs13101870>
- Ripley, B. D. (1996). Pattern recognition and neural networks.
- Ripley, B., William, V., & Maintainer, B. R. (2015). The Comprehensive R Archive Network 11.
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS. Third Earth Resources Technology Satellite-1 Symposium, 309–317.
- Sabuncu, A., Uca Avci, Z. D., & Sunar, F. (2016). Preliminary results of earthquake-induced building damage detection with object-based image classification. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 347–350.
- Sabuncu, A., Uça Avcı, Z. D., & Sunar, F. (2016). Yüksek Çözünürlüklü Uydu Verisi ile Nesne Tabanlı Sınıflandırma Uygulamasında Mevsimsel Koşulların Etkisi.
- Sadeh, Y., Zhu, X., Dunkerley, D., Walker, J. P., Zhang, Y., Rozenstein, O., Manivasagam, V. S., & Chenu, K. (2021). Fusion of Sentinel-2 and PlanetScope time-series data into daily 3 m surface reflectance and wheat LAI monitoring. *International Journal of Applied Earth Observation and Geoinformation*, 96, 102260. <https://doi.org/10.1016/j.jag.2020.102260>
- Senanda, E., (1986). Physical Fundamentals of Remote sensing,, Berlin: Springer Verlag.
- Şallı, B. (2020). Planet Uydu Görüntü Verileriyle Yüksek Doğruluklu Domates Ürün Tipi Sınıflandırmasında Rastgele Orman Sınıflandırma Yönteminin Kullanımı ve Doğruluk Analizi.
- Schowengerdt, R. A. (1980). Reconstruction of multispatial, multispectral image data using spatial frequency content. In *Photogrammetric Engineering and Remote Sensing* 46.10 (pp. 1325–1334).
- Şerifoğlu Yılmaz, Ç., Yılmaz, V., & Güngör, O. (2021). Çok Bantlı Görüntülerde Pan-Keskinleştirme Üzerine Bir İnceleme. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11, 1340–1357. <https://doi.org/10.17714/gumusfenbil.972014>
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. In *Remote Sensing of Environment* (pp. 127–150).
- Vaiopoulos, A. D., & Karantzalos, K. (2016). Pansharpening On The Narrow VNIR And SWIR Spectral Bands Of Sentinel-2. *ISPRS- International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B7, 723–730. <https://doi.org/10.5194/isprs-archives-xli-b7-723-2016>
- Venables, W. N., & Ripley, B. D. (2002). *Modern Applied Statistics with S*. Fourth edition. Springer.

World population projected to reach 9.8 billion in 2050, and 11.2 billion in 2100 | United Nations. (2019). United Nations Raport. <https://www.un.org/en/desa/world-population-projected-reach-98-billion-2050-and-112-billion-2100>

Zhang, P., Hu, S., Li, W., & Zhang, C. (2020). Parcel-level mapping of crops in a smallholder agricultural area: A case of central China using single-temporal VHRS imagery. *Computers and Electronics in Agriculture*, 175, 105581. <https://doi.org/10.1016/J.COMPAG.2020.105581>

Http-1: <https://www.tarimorman.gov.tr/SYGM/Belgeler/havza%20tanıtım%2023.03.2023/türkçe/Gediz%20Havzası%20Tanıtım.pdf> (Erişim tarihi: 06.03.2023)

Http-2: http://www.zamandayolculuk.com/html-3/em_spektrum.htm (Erişim tarihi: 15.05.2023)

Http-3: https://science.nasa.gov/ems/08_nearinfraredwaves (Erişim tarihi: 15.06.2023)

Http-4: <https://earthdata.nasa.gov/learn/backgrounders/remote-sensing> (Erişim tarihi: 15.06.2023)

Http-5: https://www.esa.int/Enabling_Support/Space_Transportation/Types_of_orbits (Erişim tarihi: 15.06.2023)

Http-6: <http://hosting.soonet.ca/eliris/remotesensing/bl130lec10.html> (Erişim tarihi: 01.08.2023)

Http-7: <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi> (Erişim tarihi: 01.08.2023)

Http-8: <https://developers.planet.com/docs/data/planetscope/> (Erişim tarihi: 01.08.2023)

Http-9: <https://www.indexdatabase.de/> (Erişim tarihi: 23.05.2023)

EK-1 S2 domates ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Domates	Sentinel-2 Eğitim				Sentinel-2 Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	511	207	172	1363	413	96	154	903
B3	968	221	459	1834	823	125	391	1212
B4	758	384	186	2321	625	206	235	1605
B5	1515	300	651	2633	1383	216	615	2050
B6	3661	559	1914	4758	3482	647	1644	4911
B7	4220	675	2080	5480	4079	772	1865	6015
B8	4392	713	2144	5656	4207	811	1847	6237
B8A	4371	663	2259	5553	4238	762	2018	6121
B11	2214	445	1553	3946	1899	221	1472	2731
B12	1341	457	755	3049	1098	251	754	1994
NDVI	0,7	0,17	0,18	0,93	0,73	0,13	0,15	0,9
Index3	7,2	4,2	1	30	7,3	3,3	1	18
Index5	0,72	0,094	0,45	0,88	1,1	0,19	0,22	1,3
Index6	1	0,25	0,27	1,4	0,74	0,072	0,44	0,87
Index7	0,16	0,033	0,089	0,25	0,15	0,025	0,087	0,24
Index8	0,53	0,17	-0,008	0,73	0,57	0,14	0,042	0,77
Index9	-0,17	0,12	-0,5	0,17	-0,15	0,11	-0,38	0,15
Index10	2,6	1,2	0,48	7,3	2,7	1	0,44	6,1
Index11	73	26	29	181	61	13	26	121
Index12	2,5	0,94	0,59	5,2	2,7	0,94	0,6	5
Index13	1,1	0,082	0,82	1,2	1,1	0,062	0,81	1,2
Index14	3,9	1,5	0,86	9	4,3	1,3	0,79	8,9
Index15	-0,037	0,23	-0,6	0,51	0,014	0,17	-0,61	0,43
Index16	0,33	0,2	-0,24	0,71	0,38	0,16	-0,26	0,67
Index17	3205	1014	1348	7352	2684	508	1170	4906
Index18	3,3	0,5	2,1	4,9	3,7	0,57	2,3	5,9
Index20	0,32	0,14	-0,083	0,51	0,37	0,12	-0,063	0,54
Index21	3634	1026	654	5305	1,8	0,42	0,26	2,5
Index22	3634	1026	654	5305	3582	964	560	5851
Index23	3,7	1,4	0,78	8,8	4,1	1,3	0,74	8,6
Index24	0,8	0,19	0,18	1,1	0,84	0,15	0,16	1
Index25	0,67	0,053	0,52	0,86	0,67	0,048	0,53	0,84
Index26	0,22	0,034	0,13	0,31	0,25	0,027	0,17	0,34
Index27	1631	731	29	3623	1630	697	39	3232
Index28	4893	2194	86	10868	4889	2090	118	9697
Index29	180	256	-512	960	133	213	-374	661
Index30	0,17	0,12	-0,17	0,5	0,15	0,11	-0,15	0,38

EK-2 S2 mısır ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Mısır	Sentinel-2 Eğitim				Sentinel-2 Test			
	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	254	152	115	1253	248	114	110	1542
B3	543	208	287	1770	518	152	304	2072
B4	382	262	171	2224	358	211	149	2765
B5	829	312	439	2506	793	247	451	3100
B6	2788	419	1977	4809	2855	361	1513	4766
B7	3703	501	2243	5964	3940	484	1650	5827
B8	3847	524	2293	6177	4075	520	1633	6066
B8A	3885	498	2392	6104	4120	494	1840	5913
B11	1818	312	1379	3674	1784	224	1312	4135
B12	970	320	639	3000	908	240	566	3166
NDVI	0,82	0,11	0,16	0,93	0,84	0,1	0,094	0,94
Index3	13	4,7	1	65	13	3,8	1	34
Index5	0,81	0,071	0,44	0,89	1,3	0,15	0,14	1,4
Index6	1,2	0,17	0,24	1,4	0,82	0,063	0,41	0,91
Index7	0,11	0,03	0,073	0,26	0,1	0,025	0,061	0,25
Index8	0,6	0,11	-0,0046	0,74	0,63	0,1	-0,082	0,79
Index9	-0,21	0,083	-0,45	0,14	-0,21	0,076	-0,4	0,15
Index10	4,5	1,4	0,46	8,6	4,8	1,3	0,38	10
Index11	39	20	19	166	37	15	19	209
Index12	3,2	0,83	0,59	5,5	3,5	0,79	0,51	6,8
Index13	1,1	0,053	0,81	1,2	1,2	0,049	0,77	1,2
Index14	6,9	2	0,77	12	7,4	1,8	0,65	14
Index15	0,25	0,2	-0,61	0,55	0,27	0,17	-0,63	0,59
Index16	0,55	0,16	-0,24	0,74	0,57	0,14	-0,3	0,78
Index17	1722	818	880	6765	1641	620	897	8450
Index18	5	0,96	2	7,6	5,4	0,91	2,2	9
Index20	0,36	0,085	-0,074	0,51	0,39	0,078	-0,14	0,56
Index21	3465	640	840	5913	2,1	0,3	0,16	2,5
Index22	3465	640	840	5913	3716	634	301	5785
Index23	6,6	1,9	0,73	11	7,1	1,7	0,59	13
Index24	0,94	0,13	0,17	1,1	0,96	0,12	0,1	1,1
Index25	0,78	0,052	0,56	0,86	0,79	0,05	0,43	0,87
Index26	0,2	0,027	0,061	0,35	0,2	0,031	0,14	0,35
Index27	1013	668	90	14847	936	362	28	3676
Index28	3038	2003	271	44542	2809	1087	85	11027
Index29	157	182	-516	3452	145	117	-642	737
Index30	0,21	0,083	-0,14	0,45	0,21	0,076	-0,15	0,4

EK-3 S2 pamuk ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Pamuk	Sentinel-2 Eğitim				Sentinel-2 Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	363	159	149	1285	278	65	156	812
B3	787	194	328	1767	659	91	356	1136
B4	522	275	206	2145	358	138	194	1434
B5	1288	268	481	2347	1149	154	595	1725
B6	3711	624	1991	5110	4079	595	1927	5368
B7	4315	770	2187	6082	4873	726	2049	6486
B8	4457	815	2273	6419	5010	762	2075	6723
B8A	4418	765	2374	6196	4976	721	2159	6598
B11	2075	304	1478	3692	2032	159	1443	2674
B12	1131	344	653	3307	984	168	679	1868
NDVI	0,78	0,13	0,13	0,93	0,86	0,079	0,26	0,93
Index3	11	5,9	1	26	16	5,4	1	28
Index5	0,77	0,085	0,42	0,89	1,3	0,12	0,39	1,4
Index6	1,2	0,2	0,2	1,4	0,83	0,05	0,49	0,89
Index7	0,14	0,035	0,069	0,26	0,11	0,02	0,076	0,22
Index8	0,59	0,13	-0,08	0,78	0,66	0,089	0,072	0,77
Index9	-0,25	0,12	-0,49	0,13	-0,32	0,11	-0,5	0,14
Index10	3,6	1,5	0,41	7,6	4,9	1,3	0,61	7,6
Index11	55	20	22	170	42	8,9	24	111
Index12	3,1	1,2	0,52	6,1	4	0,99	0,69	6,1
Index13	1,1	0,063	0,8	1,2	1,2	0,037	0,87	1,2
Index14	5,2	2	0,59	12	6,8	1,5	1,2	11
Index15	0,14	0,24	-0,64	0,48	0,29	0,14	-0,48	0,51
Index16	0,45	0,19	-0,3	0,72	0,58	0,11	-0,14	0,72
Index17	2458	802	1010	6963	1952	354	1077	4516
Index18	3,5	0,77	1,9	8	4	0,62	2,6	6,8
Index20	0,35	0,1	-0,13	0,52	0,41	0,068	-0,0071	0,52
Index21	3935	1010	661	6093	2,3	0,28	0,43	2,6
Index22	3935	1010	661	6093	4653	859	853	6481
Index23	5	1,9	0,52	11	6,6	1,4	1,2	10
Index24	0,9	0,16	0,13	1,1	0,99	0,091	0,29	1,1
Index25	0,68	0,062	0,48	0,87	0,71	0,036	0,56	0,85
Index26	0,24	0,034	0,14	0,33	0,27	0,023	0,15	0,34
Index27	2079	929	98	5782	2555	901	246	5346
Index28	6236	2786	293	17346	7664	2703	739	16039
Index29	315	260	-344	1220	430	247	-332	1190
Index30	0,25	0,12	-0,13	0,49	0,32	0,11	-0,14	0,5

EK-4 S2 üzüm ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Üzüm	Sentinel-2 Eğitim				Sentinel-2 Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	512	177	166	1480	459	123	216	981
B3	936	205	397	2025	843	163	448	1421
B4	846	317	203	2611	781	205	275	1730
B5	1453	275	611	2914	1362	217	682	2061
B6	3062	381	1804	4604	2868	378	1849	4066
B7	3556	478	1909	5397	3367	455	2049	4779
B8	3677	517	1917	5630	3463	486	2014	4932
B8A	3709	490	2019	5443	3529	455	2175	4873
B11	2378	375	1176	4340	2268	327	1601	3262
B12	1590	405	647	3482	1537	337	826	2826
NDVI	0,63	0,13	0,096	0,92	0,63	0,093	0,19	0,89
Index3	4,8	2,5	1	25	4,4	1,8	1	18
Index5	0,68	0,072	0,4	0,86	0,94	0,14	0,29	1,3
Index6	0,94	0,19	0,14	1,4	0,68	0,053	0,47	0,86
Index7	0,17	0,026	0,093	0,27	0,17	0,019	0,093	0,24
Index8	0,4	0,12	-0,16	0,71	0,39	0,099	-0,018	0,68
Index9	-0,077	0,09	-0,5	0,15	-0,05	0,069	-0,33	0,18
Index10	1,9	0,79	0,37	6,1	1,9	0,6	0,53	5,8
Index11	75	23	28	194	68	16	32	135
Index12	1,7	0,57	0,47	4,9	1,6	0,43	0,59	4,1
Index13	1,1	0,063	0,77	1,2	1,1	0,045	0,83	1,2
Index14	3,2	1,1	0,46	8,2	3,3	0,85	0,97	8,3
Index15	-0,13	0,18	-0,68	0,51	-0,12	0,14	-0,56	0,39
Index16	0,24	0,16	-0,34	0,68	0,25	0,12	-0,2	0,65
Index17	3230	894	1247	7943	2926	635	1428	5553
Index18	3,5	0,51	1,7	6,1	3,8	0,49	2,4	6,2
Index20	0,22	0,088	-0,16	0,47	0,22	0,07	-0,053	0,42
Index21	2832	677	390	5286	1,4	0,28	0,31	2,3
Index22	2832	677	390	5286	2682	541	662	4579
Index23	3	1	0,42	7,7	3,1	0,81	0,93	7,6
Index24	0,72	0,15	0,097	1,1	0,72	0,11	0,23	1
Index25	0,68	0,036	0,4	0,84	0,68	0,027	0,58	0,82
Index26	0,22	0,028	0,089	0,34	0,24	0,024	0,17	0,3
Index27	1016	441	26	3857	908	317	103	2579
Index28	3047	1323	79	11571	2723	950	309	7738
Index29	-4,3	167	-631	936	-54	112	-397	547
Index30	0,077	0,09	-0,15	0,5	0,05	0,069	-0,18	0,33

EK-5 S2 zeytin ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Zeytin	Sentinel-2 Eğitim				Sentinel-2 Test			
	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	873	224	228	1628	609	147	200	1141
B3	1252	286	517	2217	911	178	488	1532
B4	1575	371	359	2792	1115	267	261	1940
B5	1918	365	863	3151	1443	253	696	2340
B6	2585	367	1841	3958	2246	328	1466	3914
B7	2880	400	1994	4613	2587	436	1601	4537
B8	2976	415	2093	4888	2649	458	1608	4721
B8A	3051	393	2187	4762	2752	450	1777	4710
B11	2899	400	1910	4265	2300	320	1709	3498
B12	2330	374	1110	3378	1733	325	783	2782
NDVI	0,32	0,096	0,12	0,86	0,4	0,13	0,11	0,89
Index3	1,5	1	1	14	2,3	1,9	1	17
Index5	0,52	0,051	0,42	0,84	0,61	0,19	0,17	1,3
Index6	0,47	0,14	0,18	1,3	0,57	0,069	0,42	0,86
Index7	0,21	0,02	0,092	0,26	0,19	0,025	0,09	0,25
Index8	0,12	0,087	-0,1	0,59	0,21	0,13	-0,078	0,71
Index9	0,11	0,041	-0,23	0,17	0,091	0,067	-0,3	0,19
Index10	0,76	0,35	0,4	5,2	1,1	0,67	0,4	5,9
Index11	121	29	36	215	86	19	31	150
Index12	0,8	0,23	0,51	3,1	1	0,49	0,52	4,4
Index13	0,9	0,052	0,79	1,2	0,95	0,066	0,78	1,2
Index14	1,5	0,61	0,61	8,3	2,1	1	0,7	8,6
Index15	-0,47	0,1	-0,64	0,35	-0,37	0,15	-0,64	0,4
Index16	-0,094	0,11	-0,3	0,62	0,0091	0,15	-0,3	0,66
Index17	4952	1157	1621	8768	3545	757	1436	6097
Index18	3,1	0,52	1,9	6,2	3,6	0,64	2,2	5,5
Index20	0,026	0,066	-0,15	0,37	0,086	0,096	-0,14	0,45
Index21	1402	433	578	4374	0,83	0,34	0,22	2,3
Index22	1402	433	578	4374	1534	597	330	4396
Index23	1,4	0,57	0,58	7,7	2	0,98	0,69	8,2
Index24	0,35	0,11	0,11	0,98	0,46	0,15	0,12	1
Index25	0,68	0,053	0,45	0,87	0,7	0,055	0,5	0,82
Index26	0,22	0,026	0,13	0,3	0,23	0,026	0,16	0,31
Index27	290	215	-35	3289	333	243	27	2141
Index28	871	645	-106	9867	998	728	81	6422
Index29	-355	96	-619	493	-253	109	-471	280
Index30	-0,11	0,041	-0,17	0,23	-0,091	0,067	-0,19	0,3

EK-6 PS domates ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Domates	PlanetScope Eğitim				PlanetScope Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B1	647	149	423	1256	536	71	381	846
B2	1083	174	694	1762	940	97	650	1230
B3	907	310	477	2190	784	163	476	1560
B4	4343	590	2493	5313	4196	637	2279	5690
NDVI	0,65	0,13	0,22	0,83	0,68	0,098	0,24	0,82
Index2	0,11	0,079	-0,12	0,28	0,098	0,068	-0,12	0,22
Index3	1,8	0,46	0,44	2,5	1,7	0,35	0,44	2,4
Index4	0,97	0,2	0,34	1,2	1	0,15	0,36	1,2
Index5	1,5	0,00011	1,5	1,5	1,5	0,000092	1,5	1,5
Index6	3435	841	1004	4741	3412	756	983	5103
Index7	0,57	0,17	0,049	0,82	0,6	0,13	0,056	0,78
Index8	0,59	0,091	0,33	0,73	0,63	0,064	0,35	0,75
Index9	-0,32	0,16	-0,73	0,044	-0,29	0,14	-0,72	-0,0037
Index10	0,78	0,12	0,37	0,91	0,8	0,08	0,39	0,9

EK-7 PS mısır ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Mısır	PlanetScope Eğitim				PlanetScope Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B1	463	106	359	1172	423	79	325	1239
B2	752	158	554	1680	708	116	550	1795
B3	594	209	412	2099	565	168	394	2328
B4	3897	431	2693	5786	4094	403	2227	5798
NDVI	0,74	0,083	0,23	0,84	0,76	0,076	0,21	0,86
Index2	0,13	0,046	-0,12	0,29	0,12	0,044	-0,13	0,26
Index3	2,1	0,3	0,42	2,4	2,1	0,27	0,37	2,5
Index4	1,1	0,13	0,34	1,3	1,1	0,11	0,32	1,3
Index5	1,5	0,000055	1,5	1,5	1,5	0,000063	1,5	1,5
Index6	3303	515	1186	5294	3529	495	839	5319
Index7	0,69	0,11	0,043	0,83	0,71	0,099	0,02	0,84
Index8	0,68	0,064	0,33	0,77	0,7	0,056	0,32	0,8
Index9	-0,18	0,12	-0,73	0,082	-0,14	0,11	-0,73	0,14
Index10	0,84	0,069	0,36	0,91	0,86	0,063	0,35	0,92

EK-8 PS pamuk ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Pamuk	PlanetScope Eğitim				PlanetScope Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B1	533	111	385	1123	435	45	343	725
B2	933	146	584	1643	807	67	578	1096
B3	701	219	445	1958	563	109	450	1265
B4	4413	670	2478	6034	4867	612	2435	6196
NDVI	0,72	0,11	0,22	0,85	0,79	0,065	0,32	0,86
Index2	0,16	0,07	-0,097	0,27	0,18	0,06	-0,096	0,31
Index3	2	0,37	0,43	2,5	2,2	0,25	0,58	2,5
Index4	1,1	0,16	0,33	1,3	1,2	0,098	0,47	1,3
Index5	1,5	0,000079	1,5	1,5	1,5	0,000047	1,5	1,5
Index6	3712	829	1063	5419	4304	693	1170	5740
Index7	0,66	0,14	0,045	0,84	0,74	0,088	0,13	0,85
Index8	0,64	0,083	0,3	0,77	0,71	0,046	0,4	0,78
Index9	-0,2	0,17	-0,73	0,11	-0,065	0,13	-0,68	0,15
Index10	0,83	0,085	0,36	0,92	0,88	0,048	0,48	0,93

EK-9 PS üzüm ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Üzüm	PlanetScope Eğitim				PlanetScope Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B1	638	125	395	1320	577	96	390	995
B2	1057	157	598	1892	974	134	640	1487
B3	962	254	474	2486	906	162	517	1733
B4	3773	426	2276	5193	3645	398	2328	4848
NDVI	0,59	0,098	0,18	0,82	0,6	0,069	0,26	0,78
Index2	0,059	0,059	-0,14	0,26	0,04	0,045	-0,14	0,23
Index3	1,5	0,33	0,33	2,4	1,5	0,24	0,46	2,2
Index4	0,89	0,15	0,27	1,2	0,9	0,1	0,39	1,2
Index5	1,5	0,000082	1,5	1,5	1,5	0,00006	1,5	1,5
Index6	2810	550	798	4614	2739	437	968	4265
Index7	0,49	0,12	-0,0026	0,8	0,49	0,088	0,07	0,75
Index8	0,56	0,066	0,25	0,72	0,58	0,047	0,34	0,73
Index9	-0,42	0,12	-0,75	0,0046	-0,42	0,086	-0,71	-0,091
Index10	0,74	0,086	0,3	0,9	0,75	0,057	0,42	0,88

EK-10 PS zeytin ürünü eğitim ve test verileri için tamamlayıcı istatistikler

Zeytin	PlanetScope Eğitim				PlanetScope Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B1	951	158	511	1500	686	104	385	1073
B2	1360	221	808	2116	1027	134	662	1492
B3	1618	299	656	2648	1190	212	487	1840
B4	3174	349	2415	4710	2898	387	2143	4576
NDVI	0,33	0,076	0,16	0,75	0,42	0,095	0,21	0,81
Index2	-0,083	0,03	-0,13	0,13	-0,067	0,045	-0,14	0,16
Index3	0,7	0,22	0,3	2,1	0,9	0,29	0,38	2,3
Index4	0,49	0,11	0,24	1,1	0,62	0,14	0,32	1,2
Index5	1,5	0,00011	1,5	1,5	1,5	0,00012	1,5	1,5
Index6	1557	366	804	3968	1708	495	869	4089
Index7	0,17	0,091	-0,023	0,71	0,26	0,12	0,024	0,78
Index8	0,4	0,055	0,25	0,7	0,47	0,066	0,32	0,74
Index9	-0,66	0,06	-0,76	-0,17	-0,6	0,1	-0,73	-0,031
Index10	0,49	0,081	0,27	0,86	0,58	0,091	0,35	0,89

EK-11 Pan görüntü domates ürünü tamamlayıcı istatistikler

Domates	Pan-Keskinleştirme Eğitim				Pan-Keskinleştirme Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	506	212	167	1509	411	97	150	911
B3	967	224	459	1974	822	128	385	1222
B4	746	395	186	2602	621	209	229	1632
B5	1521	294	652	2612	1385	217	615	2051
B6	3691	571	1909	4774	3490	657	1619	4939
B7	4251	690	2069	5495	4088	785	1825	6047
B8	4438	753	2128	5688	4252	779	1967	6169
B8A	4411	690	2235	5592	4225	831	1808	6286
B11	2216	441	1547	3917	1900	219	1470	2747
B12	1339	454	756	3032	1098	249	754	2010
NDVI	0,7	0,17	0,13	0,93	0,73	0,13	0,13	0,9
Index3	8	4,3	1,3	30	7,9	3,4	1,3	20
Index5	1,1	0,26	0,2	1,4	1,1	0,19	0,2	1,4
Index6	0,72	0,097	0,43	0,88	0,74	0,074	0,43	0,87
Index7	0,16	0,034	0,089	0,25	0,15	0,025	0,087	0,25
Index8	0,53	0,17	-0,013	0,72	0,57	0,14	0,033	0,77
Index9	-0,17	0,13	-0,5	0,17	-0,16	0,11	-0,4	0,15
Index10	0,31	0,092	0,038	0,45	0,32	0,071	0,038	0,43
Index11	73	27	29	199	61	13	25	122
Index12	2,5	0,95	0,58	5,2	2,7	0,95	0,6	5
Index13	1,1	0,086	0,79	1,2	1,1	0,063	0,79	1,2
Index14	4	1,5	0,72	9	4,3	1,4	0,77	9,1
Index15	-0,027	0,24	-0,63	0,51	0,018	0,18	-0,62	0,44
Index16	0,78	0,11	0,44	0,94	0,79	0,084	0,44	0,91
Index17	0,56	0,08	0,31	0,75	0,55	0,074	0,33	0,69
Index18	3,3	0,53	2,1	4,9	3,7	0,57	2,3	5,9
Index20	0,33	0,14	-0,081	0,51	0,37	0,12	-0,067	0,54
Index21	0,81	0,32	0,066	1,7	0,85	0,26	0,07	1,4
Index22	3692	1079	622	5282	3604	986	503	5903
Index23	3,7	1,5	0,77	8,7	4,1	1,3	0,73	8,6
Index24	0,8	0,2	0,18	1,1	0,84	0,15	0,15	1
Index25	0,7	0,18	-0,13	0,88	0,74	0,14	-0,15	0,88
Index26	0,23	0,037	0,1	0,31	0,25	0,028	0,17	0,35
Index27	1722	783	-129	3929	1669	724	29	3475
Index28	1532	486	-426	2395	1473	385	-12	2170
Index29	1241	471	-206	2312	1186	420	0,48	2030
Index30	0,17	0,13	-0,17	0,5	0,16	0,11	-0,15	0,4

EK-12 Pan görüntü mısır ürünü tamamlayıcı istatistikler

Mısır	Pan-Keskinleştirme Eğitim				Pan-Keskinleştirme Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	245	151	115	1301	245	118	-303	1535
B3	529	208	283	1826	512	156	-29	2062
B4	366	262	134	2253	352	215	-213	2751
B5	818	311	432	2511	791	249	298	3078
B6	2778	430	1970	4825	2855	368	1515	4829
B7	3698	513	2252	5987	3941	492	1654	5910
B8	3852	547	2234	6222	4131	505	1814	6020
B8A	3890	516	2397	6143	4087	533	1605	6179
B11	1805	310	1373	3690	1783	226	1308	4110
B12	960	316	634	3000	907	241	564	3222
NDVI	0,83	0,11	0,15	0,95	0,84	0,1	0,086	0,94
Index3	13	4,4	1,4	37	14	3,9	1,2	35
Index5	1,2	0,17	0,23	1,4	1,3	0,15	0,13	1,4
Index6	0,82	0,072	0,44	0,91	0,83	0,064	0,41	0,91
Index7	0,11	0,031	0,063	0,26	0,1	0,026	0,062	0,25
Index8	0,6	0,11	-0,0029	0,74	0,63	0,1	-0,083	0,78
Index9	-0,22	0,084	-0,45	0,15	-0,21	0,077	-0,41	0,15
Index10	0,38	0,063	0,045	0,46	0,39	0,056	0,023	0,46
Index11	37	20	19	170	36	16	19	208
Index12	3,3	0,83	0,59	5,5	3,5	0,79	0,51	6,6
Index13	1,2	0,054	0,81	1,2	1,2	0,05	0,77	1,2
Index14	7,1	2	0,69	14	7,5	1,9	0,62	14
Index15	0,27	0,2	-0,62	0,61	0,27	0,17	-0,64	0,58
Index16	0,86	0,072	0,45	0,95	0,87	0,066	0,42	0,95
Index17	0,58	0,052	0,34	0,72	0,58	0,05	0,33	0,7
Index18	5	0,99	1,9	7,6	5,4	0,94	2,1	9,2
Index20	0,36	0,085	-0,076	0,51	0,39	0,078	-0,14	0,55
Index21	1,2	0,28	0,083	1,8	1,2	0,25	0,042	1,8
Index22	3487	663	790	5973	3735	649	275	5910
Index23	6,8	1,9	0,68	13	7,2	1,8	0,57	13
Index24	0,95	0,13	0,17	1,1	0,97	0,12	0,094	1,1
Index25	0,82	0,11	-0,074	0,92	0,84	0,11	-0,32	0,92
Index26	0,21	0,03	0,074	0,34	0,21	0,033	0,14	0,37
Index27	1037	492	21	5422	969	388	-40	4047
Index28	915	244	-17	2470	906	211	-160	1825
Index29	752	266	-15	2653	723	215	-83	1955
Index30	0,22	0,084	-0,15	0,45	0,21	0,077	-0,15	0,41

EK-13 Pan görüntü pamuk ürünü tamamlayıcı istatistikler

Pamuk	Pan-Keskinleştirme Eğitim				Pan-Keskinleştirme Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	354	159	148	1292	274	64	160	784
B3	778	195	326	1776	654	91	356	1107
B4	505	274	204	2161	350	135	168	1376
B5	1288	269	481	2356	1152	154	595	1690
B6	3732	640	1943	5156	4096	605	1919	5381
B7	4339	790	2125	6133	4893	740	2042	6529
B8	4499	843	2199	6543	5009	737	2151	6646
B8A	4454	789	2340	6293	5046	781	2071	6863
B11	2074	301	1481	3707	2039	162	1438	2639
B12	1127	341	660	3318	987	167	677	1821
NDVI	0,79	0,14	0,13	0,93	0,86	0,079	0,26	0,93
Index3	12	6,1	1,3	26	17	5,5	1,7	29
Index5	1,2	0,2	0,19	1,4	1,3	0,12	0,39	1,4
Index6	0,77	0,086	0,42	0,89	0,83	0,05	0,49	0,89
Index7	0,14	0,036	0,069	0,26	0,11	0,02	0,076	0,22
Index8	0,59	0,13	-0,083	0,78	0,66	0,089	0,073	0,77
Index9	-0,26	0,13	-0,51	0,13	-0,32	0,1	-0,51	0,14
Index10	0,36	0,078	0,037	0,45	0,4	0,047	0,082	0,45
Index11	54	20	22	171	42	8,8	24	107
Index12	3,2	1,2	0,51	6,1	4	0,99	0,69	6,1
Index13	1,1	0,064	0,79	1,2	1,2	0,037	0,87	1,2
Index14	5,3	2	0,58	12	6,9	1,5	1,2	11
Index15	0,15	0,24	-0,64	0,49	0,3	0,14	-0,48	0,51
Index16	0,83	0,088	0,46	0,93	0,89	0,056	0,49	0,94
Index17	0,61	0,076	0,35	0,75	0,65	0,065	0,34	0,75
Index18	3,5	0,78	1,9	8	4	0,63	2,6	6,8
Index20	0,36	0,11	-0,14	0,52	0,41	0,068	-0,0071	0,52
Index21	1,1	0,35	0,063	1,6	1,3	0,24	0,15	1,7
Index22	3994	1037	639	6237	4695	875	852	6623
Index23	5,1	1,9	0,51	11	6,7	1,5	1,2	10
Index24	0,91	0,16	0,13	1,1	1	0,091	0,29	1,1
Index25	0,78	0,12	-0,16	0,9	0,84	0,063	0,21	0,89
Index26	0,25	0,037	0,14	0,34	0,27	0,025	0,15	0,38
Index27	2195	995	90	6209	2653	938	245	5440
Index28	1412	306	205	2264	1309	204	426	1885
Index29	1367	416	94	2667	1495	383	238	2644
Index30	0,26	0,13	-0,13	0,51	0,32	0,1	-0,14	0,51

EK-14 Pan görüntü üzüm ürünü tamamlayıcı istatistikler

Üzüm	Pan-Keskinleştirme Eğitim				Pan-Keskinleştirme Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	505	181	164	1571	452	124	34	1006
B3	930	210	370	2126	837	164	394	1448
B4	834	324	199	2640	770	207	251	1787
B5	1452	276	605	2944	1358	217	688	2029
B6	3061	391	1792	4622	2864	384	1842	4099
B7	3553	490	1895	5401	3362	461	2041	4820
B8	3685	536	1899	5715	3532	466	2164	4939
B8A	3715	506	1999	5498	3467	500	1937	5147
B11	2374	376	1165	4375	2263	328	1594	3265
B12	1587	405	637	3498	1533	337	836	2835
NDVI	0,63	0,13	0,082	0,93	0,63	0,095	0,17	0,9
Index3	5,4	2,7	1,2	26	5	1,9	1,4	20
Index5	0,95	0,2	0,12	1,4	0,95	0,14	0,25	1,3
Index6	0,68	0,074	0,39	0,86	0,68	0,054	0,45	0,86
Index7	0,17	0,027	0,091	0,28	0,16	0,019	0,092	0,24
Index8	0,4	0,12	-0,18	0,71	0,39	0,099	-0,036	0,67
Index9	-0,081	0,092	-0,51	0,15	-0,053	0,071	-0,35	0,18
Index10	0,26	0,069	0,023	0,45	0,26	0,051	0,05	0,43
Index11	74	23	26	205	68	16	32	139
Index12	1,7	0,58	0,45	4,9	1,6	0,44	0,56	4,1
Index13	1,1	0,065	0,76	1,2	1,1	0,046	0,82	1,2
Index14	3,2	1,1	0,42	8,4	3,3	0,87	0,89	8,4
Index15	-0,12	0,19	-0,69	0,52	-0,11	0,14	-0,57	0,4
Index16	0,73	0,08	0,45	0,93	0,72	0,06	0,44	0,91
Index17	0,49	0,059	0,33	0,75	0,47	0,048	0,3	0,66
Index18	3,5	0,53	1,7	6,4	3,8	0,49	2,3	6,2
Index20	0,22	0,089	-0,17	0,47	0,22	0,07	-0,058	0,42
Index21	0,63	0,24	0,039	1,6	0,62	0,18	0,094	1,5
Index22	2851	701	343	5388	2697	559	562	4875
Index23	3,1	1,1	0,39	7,9	3,2	0,81	0,88	7,7
Index24	0,72	0,15	0,084	1,1	0,72	0,11	0,22	1
Index25	0,67	0,15	-0,41	0,87	0,69	0,091	0,016	0,87
Index26	0,22	0,031	0,11	0,36	0,24	0,026	0,16	0,33
Index27	1058	480	-1,9	3907	936	348	60	2957
Index28	1250	272	-65	1883	1181	254	104	1772
Index29	860	277	-35	2019	781	222	38	1685
Index30	0,081	0,092	-0,15	0,51	0,053	0,071	-0,18	0,35

EK-15 Pan görüntü zeytin ürünü tamamlayıcı istatistikler

Zeytin	Pan-Keskinleştirme Eğitim				Pan-Keskinleştirme Test			
Değişken	Ort.	Standart Sapma	Min.	Maks.	Ort.	Standart Sapma	Min.	Maks.
B2	872	229	211	1655	605	151	199	1144
B3	1251	292	496	2259	905	181	486	1537
B4	1573	380	322	2867	1112	271	260	1948
B5	1915	371	823	3174	1433	256	696	2333
B6	2580	374	1830	4019	2231	333	1420	3944
B7	2873	409	1989	4678	2571	442	1538	4576
B8	2970	428	2086	4969	2732	457	1709	4718
B8A	3044	403	2178	4829	2626	467	1558	4811
B11	2894	405	1911	4254	2286	322	1705	3491
B12	2327	379	1110	3395	1722	327	787	2784
NDVI	0,31	0,098	0,12	0,87	0,4	0,13	0,11	0,89
Index3	2,1	1,1	1,3	15	2,7	2	1,2	18
Index5	0,47	0,15	0,17	1,3	0,6	0,19	0,16	1,3
Index6	0,52	0,052	0,41	0,85	0,57	0,07	0,42	0,86
Index7	0,21	0,02	0,088	0,26	0,19	0,025	0,09	0,25
Index8	0,12	0,088	-0,11	0,6	0,2	0,13	-0,076	0,71
Index9	0,11	0,042	-0,23	0,17	0,092	0,068	-0,3	0,19
Index10	0,11	0,044	0,032	0,41	0,15	0,062	0,029	0,42
Index11	121	29	34	221	86	19	31	151
Index12	0,8	0,24	0,5	3,3	1	0,5	0,51	4,4
Index13	0,9	0,053	0,78	1,2	0,95	0,066	0,78	1,2
Index14	1,5	0,63	0,57	8,7	2,1	1	0,67	8,6
Index15	-0,47	0,11	-0,64	0,39	-0,38	0,15	-0,65	0,4
Index16	0,53	0,053	0,44	0,89	0,58	0,076	0,43	0,91
Index17	0,36	0,031	0,31	0,58	0,38	0,049	0,28	0,64
Index18	3,1	0,53	1,9	6,3	3,6	0,64	2,2	5,6
Index20	0,026	0,067	-0,15	0,39	0,086	0,096	-0,14	0,45
Index21	0,21	0,12	0,057	1,4	0,3	0,19	0,051	1,4
Index22	1397	446	553	4478	1513	604	298	4398
Index23	1,4	0,59	0,57	8,1	2	0,99	0,65	8,3
Index24	0,35	0,11	0,11	1	0,46	0,15	0,11	1
Index25	0,34	0,17	-0,19	0,87	0,46	0,18	-0,23	0,87
Index26	0,22	0,027	0,13	0,31	0,23	0,027	0,17	0,32
Index27	293	241	37	3438	326	255	30	2274
Index28	522	200	52	1592	535	230	39	1721
Index29	272	153	15	1508	295	183	14	1521
Index30	-0,11	0,042	-0,17	0,23	-0,092	0,068	-0,19	0,3

ÖZGEÇMİŞ

ORCID NO: 0009-0007-4909-1985

Ad Soyad : İbrahim TAŞCI

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2014, Yıldız Teknik Üniversitesi, Harita Mühendisliği, Lisans
- 2018, Anadolu Üniversitesi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri, Yüksek Lisans
- 2024, Eskişehir Teknik Üniversitesi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri, Doktora
- 2010, Başarsoft Yazılım, Tekniker
- 2012, Geomobis Mobile Bilgi Sistemleri, Tekniker
- 2013, Şimşek Mühendislik, Saha Direktörü
- 2013, Alka Çevre, CBS Uzmanı
- 2014, Saudi Turki Informational Technology, Proje Yöneticisi
- 2014, BOTAŞ-TANAP Projesi, CBS Şefi
- 2019, Arı Grup Gayrimenkul, Şirket Ortağı
- 2019, GeoMahall Mekansal Yazılım Sistemleri, Şirket Sahibi
- 2023, Yeditepe Grup Gıda, Şirket Ortağı
- 2023, Nefes Grup Gıda, Şirket Ortağı

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- 2018, VII. UZAL-CBS, Orta Çözünürlüklü Uydu Görüntülerinden Değişim Saptama ile Yanmış Orman Alanların Haritalanması
- 2024, GSI Journals, Tarım Ürünlerinin Tespiti ve Sınıflandırılmasında Planet ve Sentinel-2 Uydu Görüntülerinin Füzyonu: Manisa Örneği

Mesleki Birlik/Dernek/Kuruluş Üyelikleri:

- Mimar Mühendisler Grubu