

**ASMALARIN HARİTALANMASINDA FARKLI SINIFLANDIRMA
YAKLAŞIMLARI VE ALGORİTMALARININ BAŞARILARININ
ARAŞTIRILMASI**

Mücahit ÖZTÜRK

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

Temmuz 2021

ÖZET

ASMALARIN HARİTALANMASINDA FARKLI SINIFLANDIRMA YAKLAŞIMLARI VE ALGORİTMALARININ BAŞARILARININ ARAŞTIRILMASI

Mücahit ÖZTÜRK

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2021

Danışman: Prof. Dr. Alper ÇABUK

(İkinci Danışman: Dr. Öğr. Üyesi Resul ÇÖMERT

Tarımsal ürünlerin haritalanması ve izlenmesi; verim tespiti, çiftçi denetimi ve ürün denetimi gibi nedenlerden dolayı önemlidir. Günümüzde uzaktan algılama teknolojileri ile elde edilen görüntüler ve uydu görüntüsü sınıflandırma gibi farklı bilgi çıkarma yöntemleri tarımsal alanlardaki ürünlerinin haritalanmasında başarılı şekilde uygulanmaktadır. Bu çalışmada, PlanetScope uydu sistemlerinden elde edilen görüntülere farklı sınıflandırma yaklaşımları ve algoritmaları uygulanarak asmaların haritalanmasındaki başarısı araştırılmıştır. Çalışma alanı olarak Manisa ili Saruhanlı ilçesinde asma yetiştiriciliğinin yoğun olarak yapıldığı bir bölge seçilmiştir. Haritalama işlemi için piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımları kullanılmıştır. Piksel tabanlı sınıflandırma yaklaşımında En Çok Olabilirlik (EÇO), Rastgele Orman (RO), Destek vektör makineleri (DVM) algoritmaları kullanılmıştır. Nesne tabanlı sınıflandırma yaklaşımında ise DVM, RO, Naive Bayes (NB), K-En Yakın Komşuluk (K-EYK) ve Karar Ağacı (KA) algoritmaları kullanılmıştır. Asmaların haritalanmasında hem piksel hem de nesne tabanlı sınıflandırma yaklaşımında RO algoritması en başarılı algoritma olarak tespit edilmiştir. RO algoritması ile piksel tabanlı yapılan sınıflandırmada %87 genel doğruluk, 0.83 Kappa değeri ile asmalarda %85 üretici ve %85 kullanıcı doğruluğu elde edilmiştir. Algoritma ile nesne tabanlı sınıflandırmada genel doğruluk %91, Kappa değeri 0.87, asmalar için %88 kullanıcı ve %92 üretici doğruluğu elde edilmiştir. Üretilen

haritalar incelendiğinde nesne tabanlı sınıflandırma yaklaşımı, asma parselleri için piksel tabanlı sınıflandırmada tuz-biber etkisi gibi ortaya çıkan yanlış piksel sınıflandırma hatalarını ortadan kaldırmıştır.

Anahtar Sözcükler: Asma, PlanetScope uyduları, Piksel tabanlı sınıflandırma, Nesne tabanlı sınıflandırma, Sınıflandırma algoritmalar



ABSTRACT

INVESTIGATION THE SUCCESS OF DIFFERENT CLASSIFICATION APPROACHES AND DIFFERENT CLASSIFICATION ALGORITHMS IN MAPPING VINEYARDS

Mücahit ÖZTÜRK

Department of Department of Remote Sensing and Geographic Information Systems

Programme in

Eskişehir Technical University, Institute of Graduate Programs, July 2021

Supervisor: Prof. Dr. Alper ÇABUK

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

Mapping and monitoring of agricultural products is important for reasons such as yield determination, farmer inspection, product inspection. Today, different information extraction methods such as satellite image classification are successfully applied in the mapping of agricultural products. In this study, the success of the images obtained from PlanetScope satellite systems in mapping vineyards was investigated. As the study area, a region where vineyards were intense in Saruhanlı district of Manisa province was selected. Object-based and pixel-based classification approaches were used for the mapping process. Maximum Likelihood (ML), Random Forest (RF), Support Vector Machine (SVM) algorithms are used in the pixel-based classification process. In the object-based classification approach, SVM, RF, Naive Bayes (NB), K-Nearest Neighborhood (K-NN) and Decision Tree (DT) algorithms were used. The RF algorithm was found to be the most successful algorithm in both pixel and object-based classification approaches in the mapping of vineyards. In the pixel-based classification with the RF algorithm, 87% overall accuracy, 0.83 kappa value and 85% producer and user accuracy in vineyards were obtained. In the object-based classification process with the algorithm; overall accuracy, kappa, user accuracy, and producer accuracy were determined as 91%, 0.87%, 88%, and 92%, respectively. When the generated maps were examined, the object-based classification approach has eliminated the false pixel classification errors such as the salt-pepper effect in pixel-based classification for vineyards parcels.

Keywords: Vineyards, PlanetScope satellites, Pixel-based classification, Object-based classification, Classification algorithms.



TEŞEKKÜR

Doktora sürecim boyunca bilgi ve birikimlerini benimle paylaşan, her konuda ve koşulda desteklerini benden eksik etmeyen, tecrübe ve deneyimleri ile önümü açan, tez sürecimin verimli ve kusursuz bir şekilde ilerlemesini sağlayan tez danışmanlarım Prof. Dr. Alper ÇABUK ve Dr. Öğr. Üyesi Resul ÇÖMERT'e; Tez çalışmamın tüm süreçlerinde bilgi ve deneyimleri ile bana destek veren İbrahim TAŞÇI'ya, tezimi inceleyip görüş ve önerilerini benimle paylaşan Prof. Dr. Halit APAYDIN'a, ve Prof. Dr. Ali KOÇ'a, hayatımın her aşamasında olduğu gibi tez sürecimde de en ufak tereddüt göstermeden her türlü maddi ve manevi desteğini esirgemeyen babam Kudret ÖZTÜRK'e en içten dileklerle teşekkür ederim.

Mücahit ÖZTÜRK

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.

Mücahit ÖZTÜRK

İÇİNDEKİLER Sayfa

BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI	ii
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	viii
İÇİNDEKİLER	ix
TABLolar DİZİNİ	xii
ŞEKİLLER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xv
1. GİRİŞ.....	1
1.1. Uzaktan Algılama ve Asma Haritalama ile İlgili Literatür.....	4
1.2. Tezin Önemi ve Amacı	7
1.3. Tezin Yapısı.....	8
2. UZAKTAN ALGILAMANIN KURAMSAL TEMELLERİ.....	8
2.1. Elektromanyetik Enerji.....	9
3.2. Elektromanyetik Spektrum.....	9
3.3. Elektromanyetik Enerjiye Atmosferik Etkiler	11
3.4. Cisimlerin Spektral Yansıması	13
3.4.1. Bitkilerin spektral yansıması	15

3.5. Uzaktan Algılama Sistemleri.....	17
3.5.1. Uzaktan algılama verilerinin elde edilmesi.....	18
3.5.2. Algılayıcı tipleri.....	19
3.5.3. Uydu yörüngeleri ve tarama alanı.....	20
3.5.4. Uydu Görüntüleri.....	20
3.5.5. Görüntü Ön işleme.....	22
3.5.5.1. Geometrik düzeltme.....	22
3.5.5.2. Radyometrik düzeltme.....	23
3.5.5.3. Görüntü keskinleştirme.....	23
3.5.6. Uydu Görüntülerinden Bilgi Çıkarma.....	24
3. ÇALIŞMA ALANI	25
3.1. Çalışma Alanına Ait Genel Bilgiler	25
3.2. Çalışma Alanında Asma Yetiştiriciliği.....	28
4. PLANETSCOPE UYDULARI	30
5. YÖNTEM	33
5.1. Piksel Tabanlı Sınıflandırma	35
5.1.1. Kontrolsüz Sınıflandırma.....	36
5.1.2. Kontrollü Sınıflandırma	37
5.2. Nesne Tabanlı Sınıflandırma	38
5.2.1. Görüntü Segmentasyonu	39
5.2.2. Görüntü Metrikleri	40
5.2.2.1. Spektral metrikler	40
5.2.2.2. Şekilsel metrikler	41
5.2.2.3. Dokusal Metrikler.....	42
5.2.3. Sınıflandırma yöntemleri.....	44
5.2.3.1. Kontrollü sınıflandırma.....	45
5.2.3.2 kural tabanlı sınıflandırma	45
5.3. Sınıflandırma Algoritmaları	46
5.3.1. En Çok Olabilirlik (EÇO) Algoritması	46
5.3.2. K-En Yakın Komşuluk (K-EYK) Algoritması	47

5.3.3. Naive Bayes (NB) Algoritması.....	47
5.3.4. Karar Ağacı (KA) Algoritması	48
5.3.5. Rastgele Orman (RO) Algoritması	50
5.3.6. Destek Vektör Makineleri (DVM) Algoritması.....	51
5.4. Doğruluk Analizi.....	52
6. ANALİZ VE BULGULAR	54
6.1. Verilerin Hazırlanması	54
6.2. Asmaların Piksel Tabanlı Haritalanması	58
6.3. Asmaların Nesne Tabanlı Haritalanması	65
7. TARTIŞMALAR	76
8. SONUÇ VE ÖNERİLER	80
KAYNAKÇA.....	81

ÖZGEÇMİŞ

TABLÖLER DİZİNİ

Sayfa

Tablo 3.1. Manisa ilinde ilçe bazında asma alanları	30
Tablo 4.1. PlanetScope uydu özellikleri	33
Tablo 4.2. PlanetScope uydu özellikleri	34
Tablo 6.1. PlanetScope Görüntü tarihlerine göre asma parsellerinin ortalama NDVI değerleri	57
Tablo 6.2. Piksel Tabanlı EÇO algoritması ile elde edilen doğruluk değerleri	63
Tablo 6.3. Piksel Tabanlı RO algoritması ile elde edilen doğruluk değerleri	64
Tablo 6.4. Piksel Tabanlı DVM algoritması ile elde edilen doğruluk değerleri	66
Tablo 6.5. Nesne tabanlı sınıflandırma işleminde kullanılan görüntü metrikleri (özellikler)	69
Tablo 6.6. Nesne Tabanlı K-EYK algoritması ile elde edilen doğruluk değerleri	70
Tablo 6.7. Nesne Tabanlı NB algoritması ile elde edilen doğruluk değerleri	71
Tablo 6.8. Nesne Tabanlı KA algoritması ile elde edilen doğruluk değerleri	73
Tablo 6.9. Nesne Tabanlı RO algoritması ile elde edilen doğruluk değerleri	74
Tablo 6.10. Nesne Tabanlı RO algoritması ile elde edilen doğruluk değerleri	76
Tablo 7.1. Asmaların haritalanmasında kullanılan sınıflandırma yaklaşımlarının ve algoritmaların karşılaştırılması	77

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Elektromanyetik Salınım	9
Şekil 2.2. Elektromanyetik Spektrum	10
Şekil 2.3. Elektromanyetik enerjiye atmosferik etkiler	12
Şekil 2.4. Cisimden yansıyan ışınım örneği	13
Şekil 2.5. Cisimden tarafından yutulan ışınım örneği	14
Şekil 2.6. Cisimden geçirilen ışınım örneği	14
Şekil 2.7. Cisimlerin Spektral Yansıması	15
Şekil 2.8. Bitkilerin Spektral Yansıması	16
Şekil 2.9. Klorofil Spektral Yansıması	16

Şekil 2.10. Uzaktan algılamanın çalışma prensibi	18
Şekil 2.11. Uzaktan algılamada kullanılan aktif ve pasif sistemler (http-2)	20
Şekil 3.1. Çalışma alanının genel görünümü	27
Şekil 3.2. Manisa’da yetiştirilen Sultani üzümü	31
Şekil 4.1. Örnek bir PlanetScope uydusu	32
Şekil 5.1. Tez çalışması kapsamında uygulanan metodolojiye ait şematik gösterim	35
Şekil 5.2. Piksel tabanlı ve nesne tabanlı sınıflandırma	36
Şekil 5.3. Doku hesaplamalarında kullanılan farklı açılar için piksel komşulukları (Uça Avcı, 2017)	44
Şekil 5.4. En yaygın kullanılan dokusal metrikler x: satır sayısı; y: sütun sayısı; Px,y: matrisin x,y koordinatlarında yer alan pikselin normalize değeri; N: satır veya sütun sayısı; μ : GLCM ortalama değeri; σ : GLCM standart sapması (Uça Avcı, 2017)	45
Şekil 5.5. Karar ağacı örneği (Köktürk, 2012)	51
Şekil 5.6. DVM algoritması ile optimum hiperdüzlemin belirlenmesi	52
Şekil 6.1. Google Earth görüntüsü ve ÇKS asma parselleri	56
Şekil 6.2. Çalışma alanına ait farklı tarihli PlanetScope görüntülerindeki NDVI değişimi	58
Şekil 6.3. Çalışma alanına ait eğitim ve test sahaları	59
Şekil 6.4. Piksel tabanlı sınıflandırma için toplanan eğitim verileri	60
Şekil 6.5. Algoritmaların doğruluk analizi işleminde kullanılan noktaların konumsal dağılımı	61
Şekil 6.6. Piksel tabanlı EÇO algoritması ile üretilen sınıflandırma haritası	62
Şekil 6.7. Piksel tabanlı RO algoritması ile üretilen sınıflandırma haritası	64
Şekil 6.8. Piksel tabanlı DVM algoritması ile üretilen sınıflandırma haritası	65
Şekil 6.9. Piksel tabanlı RO algoritması ile üretilen sınıflandırma haritası	67
Şekil 6.10. Özellik uzayı optimizasyonu sonucu	68
Şekil 6.11. Nesne tabanlı K-EYK algoritması ile üretilen sınıflandırma haritası	70
Şekil 6.12. Nesne tabanlı NB algoritması ile üretilen sınıflandırma haritası	72
Şekil 6.13. Nesne tabanlı KA algoritması ile üretilen sınıflandırma haritası	73
Şekil 6.14. Nesne tabanlı RO algoritması ile üretilen sınıflandırma haritası	75

Şekil 6.15. Nesne tabanlı DVM algoritması ile üretilen sınıflandırma haritası	76
Şekil 7.1. Piksel tabanlı ve Nesne Tabanlı Sınıflandırma tuz-biber etkisi	79



SİMGELER VE KISALTMALAR DİZİNİ

DVM	: Destek Vektör Makineleri
NDVI	: Normalize Edilmiş Fark Bitki İndeksi
RO	: Rastgele Orman
NB	: Naive Bayes
K-EYK	: K- En Yakın Komşuluk
EÇO	: En Çok Olabilirlik
KA	: Karar Ağacı



1. GİRİŞ

Tarımsal ürünler, toplumların gıda ihtiyaçlarını karşılamada en önemli faktörlerdir. Bu nedenle, bu alanlarda uygun karar verme süreçlerinin gerçekleştirilmesi, kaynak yönetimi ve makro planlama için ekili alan, mahsul oranı ve tarım zararlıları hakkında bilgilere hızlı erişimin olması gerekmektedir. Buna göre sürdürülebilir bir tarım için bir bölgedeki bitki türlerini belirlemek, bitki sağlığını izlemek, stresleri anlamak, fotosentez kapasitesini ve mahsul verimini belirlemek son derece önemlidir (Saghari vd., 2018).

Hem gelişmiş hem de gelişmekte olan ülkeler, ekonomik ve gıda güvenliği için tarıma bağımlıdır. Tarım, birçok ülkede herkes için gıda sağlamada birincil kaynaktır ve hemen hemen her ülkede ekonomik durumu geliştirmede başrol oynamaktadır (Vibhute ve Gawali 2013)

Hızlı nüfus artışı, kentleşme, sanayileşme nedeniyle tarım arazileri her geçen gün azalmaktadır. Yirmi birinci yüzyılda, tarım alanlarındaki değişimler, küresel çevresel değişimde önemli bir rol oynamaktadır. Tarımsal ürünleri tespit etmede karar vermeyi desteklemek için bilgi teknolojilerinin kullanımı ihtiyaç duyulmaktadır. Yerel, bölgesel ve makro düzeyde planlama ve yönetim için tarım ürünlerinin tespiti ve izlenmesi önemli bir rol oynamaktadır. Bu alanlarda Uzaktan Algılama (UA) ve Coğrafi Bilgi Sistemleri (CBS) kullanarak planlama ve karar sürecini daha gerçekçi, etkili yapmak mümkündür (Vibhute ve Gawali 2013) .

Tarımsal alanlarda bilgiye ulaşmak için uygun, düşük maliyetli ve hızlı bir yöntem uydu görüntülerini kullanmaktır (Wójtowicz vd., 2016). Herhangi bir planlama için son derece doğru ve hızlı bir şekilde mevcut olan uygun verilere kolay erişim esastır. Tarım sektöründe bir yanda iklim değişiklikleri, diğer yanda dengesiz nüfus artışı nedeniyle hızlı ve doğru mekânsal bilgiye erişim önemlidir (Saghari vd. 2018). Uydu verileri, uzaktan algılama teknolojisi ile birlikte tarımsal ekili/dikili alanları incelemek ve belirlemek için etkili araçlardır. Yüksek spektral çözünürlük, zamansal çözünürlük ve mekânsal çözünürlüğe sahip nitelikteki uzaktan algılanan veriler, ekili alanları ve zamansal değişiklikleri tespit etmek için kullanışlı, ekonomik ve geçerli bir yöntemdir (Sawasawa 2003).

Uzaktan algılama teknolojisi, bir bölgedeki tarım ürünlerinin sınıflandırmasını yapmakla kalmaz, aynı zamanda bir bölgenin ekili/dikili alanlarını belirleyerek performansını tahmin edebilir. Doğru karar verme ve yönetim için güncel bilgilerin gerekli olduğu göz önüne alındığında, tarım ürünleri için planlama, ekili alan ve tarım ürünlerinin performansı hakkında güncel bilgileri içerir (Báez-González vd., 2002; Saghari vd. 2018).

Uydu görüntüleri Landsat programının başlaması ile beraber tarımsal uygulamalarda 1970'li yılların ortalarından itibaren kullanılmaya başlanmıştır. 1984 yılında Landsat 5 uydusunun fırlatılması ile birlikte 30 m konumsal ve multispektral görüntülerin uzaydan elde edilmesi uzaktan algılamanın tarımsal alandaki uygulamalarını artırmıştır. Ardından 1986 yılında SPOT uyduları ile birlikte orta mekânsal çözünürlükte tarımsal ürün sınıflandırma uygulamaları gerçekleştirilmiştir. Gelişen teknoloji ile birlikte IKONOS, Quick Bird, World View, Geo-Eye gibi yüksek mekânsal çözünürlüklü uyduların uzayda yer alması ile uydu görüntüleri tarımsal alanlarda farklı amaçlar için kullanılmaya başlanmıştır (Mulla 2013).

Uydu görüntüleri kullanılarak yapılan tarımsal uygulamalarda genellikle bitki indeksleri, piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yaklaşımları kullanılmaktadır. Bitki indeksleri tarımsal uygulamalarda özellikle verim tahmini, hastalıklı bölge tespiti, zamansal izleme gibi uygulamalarda kullanılmaktadır. Piksel tabanlı ve nesne tabanlı yaklaşımlar ise genellikle tarımsal ürün sınıflandırma çalışmalarında kullanılmaktadır.

Uydu görüntülerinden piksel tabanlı sınıflandırma işlemi kontrollü ve kontrolsüz sınıflandırma şeklinde gerçekleştirilebilmektedir. Kontrolsüz sınıflandırma daha çok çalışma sahası ile ilgili herhangi bir bilgi yoksa alan hakkında genel ön bilgi elde etmek için uygulanmaktadır. Tarımsal uygulamalarda kontrollü sınıflandırma yöntemi tercih edilmektedir. Kontrollü sınıflandırma işlemi çalışma sahası hakkında bilgi olduğu zaman uygulanan bir yöntemdir. Bu yöntemde alana ait sınıflar belirlenmekte, bu sınıflara ait eğitim verisi toplanmakta ve belirlenen bir algoritma ile eğitim ve sınıflandırma işlemi gerçekleştirilmektedir. Piksel tabanlı sınıflandırma işleminde her bir piksel bir sınıfa atanmaktadır. Başka bir ifade ile sınıflandırma işlemi piksel seviyesinde yapılmaktadır. Pikselleri sınıflandırmak için piksellerin sahip olduğu spektral yansıma değerleri

kullanılmaktadır. Bu yaklaşım düşük ve orta konumsal çözünürlüklü görüntülerde başarılı sonuçlar verirken, yüksek konumsal çözünürlüklü görüntülerde sınıflar içinde anlamsız sınıf değerine sahip pikseller atayabilmektedir.

Uydu görüntüleri ile nesne tabanlı sınıflandırma işleminde piksel tabanlı sınıflandırmadan farklı olarak sınıflandırma aşamasında spektral yansıma değerlerinin yanında, şekilsel, dokusal ve geometrik özelliklerde sınıflandırmaya dahil edilmektedir. Nesne tabanlı sınıflandırma işlemi görüntü segmentasyonu, özellik hesaplama ve sınıflandırma aşamasından oluşmaktadır. Segmentasyon aşamasında benzer pikseller gruplandırılarak görüntü nesneleri oluşturulmaktadır. Sınıflandırma işlemi görüntü nesnesi seviyesinde gerçekleştirilmektedir. Özellik hesaplama aşamasında görüntü nesnelerine ait spektral, şekilsel, dokusal ve geometrik özellikler hesaplanmaktadır. Sınıflandırma işlemi kural tabanlı ve kontrollü sınıflandırma olarak iki farklı şekilde uygulanabilmektedir. Kural tabanlı sınıflandırma işleminde öncelikle sınıflar belirlenmekte daha sonra her bir sınıf için kural setleri oluşturularak sınıflandırma işlemi gerçekleştirilmektedir. Kontrollü sınıflandırma işleminde piksel tabanlı sınıflandırmada olduğu gibi sınıflar belirlenmekte, her bir sınıfa ait eğitim verisi toplanmakta ve belirlenen bir algoritma ile eğitim işlemi ve sınıflandırma işlemi gerçekleştirilmektedir.

Kontrollü sınıflandırma yöntemi hem piksel tabanlı sınıflandırmada hem de nesne tabanlı sınıflandırma işleminde ortak olarak kullanılan bir yöntemdir. Bu yöntemde eğitim ve sınıflandırma işleminin gerçekleştirilebilmesi için farklı sınıflandırma algoritmaları kullanılabilir. Piksel tabanlı sınıflandırma ile tarımsal alanlara yönelik yapılan uygulamalarda en çok olabilirlik algoritması sıklıkla tercih edilen bir yöntemdir. Bu algoritmanın yanında son dönemlerde popüler hale gelen makine öğrenme algoritmalarından rastgele orman, destek vektör makineleri, yapay sinir ağları gibi algoritmalar kullanılmaya başlanmıştır. Nesne tabanlı sınıflandırma ile tarımsal alan uygulamalarında daha çok rastgele orman, karar ağaçları, destek vektör makineleri, K-en yakın komşuluk gibi algoritmalar kullanılmaktadır.

Ülkemizde ve dünyada çok çeşitli tarımsal ürünler yetiştirilmektedir. Bunlardan bir tanesi de bağcılıktır. Dünyada 2018 yılında 7,2 milyon ha alanda üzüm üretilmektedir. Türkiye üzüm üretimi bakımından İspanya (%16), Çin (%11), Fransa (%11) ve İtalya'dan

(%9) sonra % 6'lık orana karşılık gelen 417 bin ha alanla dünyada beşinci sırada yer almaktadır (http-1).

Farklı tarımsal uygulamalarında olduğu gibi, uzaktan algılama teknolojisi asmalar hakkında düzenli, hızlı ve uygun maliyetli bilgi elde etmek için kullanılabilir. Uydu görüntüleri, asma kalitesi ve veriminin potansiyel göstergeleri olan şekil, boyut ve canlılık gibi asmanın biyofiziksel değişkenlerini tahmin etmek için yaygın olarak kullanılmıştır. Bağ parsellerinin doğru bir şekilde tespit edilmesi, bağ haritalama, tarım politikalarının desteklenmesi ve Arazi Parsel Tanımlama Sisteminin (APTS) oluşturulması için önemlidir (Sertel vd., 2012).

Günümüze kadar farklı uydu sistemleri, farklı algılayıcı platformlar asmaların haritalanmasında, bu alanlarda verim tahmininde, bu alanların zamansal izlenmesinde, alan yöntemi uygulamalarında kullanılmıştır. Bilim ve teknolojiadaki hızlı gelişmeler ile birlikte uydu sistemleri ve sınıflandırma algoritmaları her geçen gün gelişmektedir. Bundan dolayı gelişen uydu sistemlerinin ve algoritmalarının asmaların haritalanmasındaki başarısının araştırılması hassas tarım uygulamaları açısından son derece önemlidir. Bölüm 1.1'de asmalar ile ilgili uydu görüntüleri ve farklı yöntemlerle yapılan çalışmalara yer verilmiştir.

1.1. Uzaktan Algılama ve Asma Haritalama ile İlgili Literatür

Lacar vd. (2001) Güney Avustralya, Barossa Vadisi'ndeki bir bağda iki farklı üzüm çeşidini bir birinden ayırt edebilmek için uçak ile elde edilen hiperspektral görüntüleri kullanmışlardır. Yapmış oldukları çalışmada, asmaları sınıflandırma için en çok olabilirlik algoritmasını kullanmışlardır. Girdi verisi olarak hiperspektral kameradan elde ettikleri görünür ve kızıl ötesi bölgedeki 12 banttan yararlanmışlardır. Elde ettikleri sonuçları irdelediklerinde iki üzüm çeşidini %91.5 doğrulukla bir birinden ayırmışlardır (Lacar vd., 2001).

Sun vd. (2017) ABD'nin Kaliforniya eyaletinde iki farklı üzüm çeşidi üzerinde 2013 ve 2014 yıllarına ait Landsat görüntülerinden elde ettikleri Normalize edilmiş fark bitki indeksi (NDVI), yaprak alan indeksi (LAI) değerlerine göre haritaladıkları asmalardan konumsal verim kalite tahmini yapmışlardır. NDVI ve LAI'nin, büyüme mevsimi

boyunca belirli zamanlarda 0.8'lik korelasyonlar sağlayarak, konumsal verim değişkenliğinin bir öngörücüsü olarak benzer performansa sahip olduğunu belirtmişlerdir. Mevsim içi asma verimi tahmin edilebilirliğini, asma verimi ile bitki örtüsü indeksleri arasındaki ilişkinin sınırlı zemin ölçümleriyle kalibre edildiği basit bir strateji kullanılarak incelenmiştir. Bu stratejinin, şaraplık asma yetiştirme endüstrisinde kullanılan geleneksel yaklaşımlarla karşılaştırıldığında verim tahmininin doğruluğunu ve verimliliğini artırmak için güçlü bir potansiyele sahip olduğu belirtilmiştir (Sun vd., 2017).

Johnson vd. (2003) Kaliforniya'nın Kuzey Kıyısı yetiştirme bölgesindeki iki ticari şaraplık asma alanı (yaklaşık 800 ha) boyunca yaprak alanını (LA) haritalamak için IKONOS yüksek mekânsal çözünürlüklü multispektral uydu görüntülerini kullanılmıştır. Kullanılan görüntüler asmaların büyüme mevsimi boyunca elde edilmiştir. Elde edilen her bir görüntüden NDVI haritaları üretilmiş ve üretilen NDVI haritalarını LAI değerlerine dönüştürmek için 24 zemin noktasında kalibrasyon ölçümü yapılmıştır. Uydu görüntüsü tabanlı tespit edilen LA değerleri ile yersel olarak elde edilen 23 LA değeri arasında yüksek oranda korelasyon ($R^2=0.72$; $P<0.001$) olduğu görülmüştür. Elde edilen sonuçlar uydu görüntülerinden elde edilen LA değerlerinin bitki büyümelerini modellemek ve sulama yönetimi için karar destek sağlayacak potansiyelde olduğunu göstermiştir (Johnson vd., 2003).

Govedarica vd. (2015) yapmış oldukları çalışmada orman alanlarını ve asmaların nesne tabanlı görüntü analizi ile 5 m konumsal çözünürlük Rapid Eye ve 2 m mekânsal çözünürlüklü World View-2 görüntülerinden haritalama işlemini gerçekleştirmiştir. Araştırmacılar çalışmalarında kural tabanlı sınıflandırma kullanmışlardır. Elde ettikleri sonuçlar incelendiğinde yaptıkları haritalamada orman alanlarını %96.48 bağ alanlarını %83.20'lik doğrulukla haritalamışlardır (Govedarica A vd., 2015).

Karakizi vd. (2016) Yunanistan'da bağcılık tarımı yapılan farklı alanlarda 0.5 m çözünürlüklü World View-2 görüntüsünü kullanarak asmaların tespit edilmesi uygulamasını gerçekleştirmişlerdir. Tespit etme aşamasında piksel tabanlı ve nesne tabanlı görüntü analizi yaklaşımlarını kullanmışlardır. Piksel tabanlı sınıflandırmada sınıflandırma algoritması olarak Destek Vektör Makineleri (DVM), nesne tabanlı sınıflandırmada En Yakın Komşuluk (EYK) algoritmalarını kullanmışlardır. Elde ettikleri sonuçlar incelendiğinde, bağ alanlarını tespit etmede en yüksek %96, parsel seviyesinde

asmaları çıkarmada %85 başarı elde edilmiştir. Nesne tabanlı sınıflandırma ile obje tabanlı sınıflandırma karşılaştırıldığında, nesne tabanlı sınıflandırmada daha az sınıflandırma hatası yapıldığı görülmüştür (Karakizi vd., 2016)

Padua vd. (2020) insansız hava aracı (İHA) tarafından elde edilen RGB verilerinin asmaların sınıflandırmasında makine öğrenmesi yöntemlerinin başarısını araştırmışlardır. Çok yüksek mekânsal çözünürlüklü İHA tabanlı görüntülerden ortomozaik, sayısal yüzey modeli ve beş bitki örtüsü indeksi üretmişlerdir. Sınıflandırma işlemi için nesne tabanlı sınıflandırma yaklaşımı kullanılmışlardır. Çalışmada asmalar, toprak, gölge ve diğer bitkiler olmak üzere dört sınıf tanımlanmıştır. Sınıflandırma algoritması olarak destek vektör makinesi (DVM), rastgele orman (RO) ve yapay sinir ağı (ANN)) uygulanmıştır. Veriler eğitim amaçlı %22 (n=240, sınıf başına 60) ve test amaçlı %78 (n=850) olarak bölünmüştür. Sonuçlar, hem RF hem de ANN modellerinin iyi bir performans gösterdiğini, ancak RF sınıflandırıcısının daha iyi sonuçlar verdiğini göstermiştir (Pádua vd., 2020).

Sozzi vd. (2020) yaptıkları çalışmada Fransa'daki 30 bağ bloğunda yaptıkları çalışmada insansız hava aracı görüntülerinden üretilen NDVI değerleri ile Sentinel 2 görüntülerinden üretilen NDVI değerlerini karşılaştırmışlardır. Yapılan karşılaştırma sonucundan asmalarda her iki platformdan üretilen değerler arasında güçlü korelasyon olduğu görülmüştür. Çalışmada, asmalara yönelik yüksek konumsal çözünürlüklü yönetimin gerekli olmadığı durumlarda, İHA ile elde edilen görüntüler yerine Sentinel-2 vejetasyon indeksinin kullanılabileceği gösterilmiştir (Sozzi vd., 2020)

Di Gennaro vd. (2019) yaptıkları çalışmada asmalarda İHA verilerinden üretilen NDVI ve Sentinel 2 görüntülerinden elde edilen NDVI değerlerini karşılaştırmışlardır. Asmalar sıralı bir mimari şeklinde dikildiğinden görüntülerde toprak ve asmalar nedeniyle karışık piksellerin olduğunu belirtmişlerdir. İHA görüntülerine uyguladıkları filtre ile filtreli ve filtresiz NDVI üretmişlerdir. Bu iki NDVI Sentinel 2 görüntülerinden ürettikleri NDVI değerleri ile kıyaslamışlardır. Yaptıkları kıyaslama sonucunda filtreli veri ile 0.80, filtresiz veri ile 0.60 korelasyon sonucuna ulaşmışlardır. Elde ettikleri bu sonuç yetişmiş asmaların hassas yönetiminde Sentinel 2 verilerinin kullanılabilir olduğunu göstermiştir (Di Gennaro vd., 2019)

Hernandez vd. (2020) Portekiz’de yaptıkları çalışmada Sentinel 2 görüntülerinin tarımsal ürün sınıflandırmadaki başarısını araştırmışlardır. Sınıflandırma işlemi piksel tabanlı olarak gerçekleştirilmiştir. Sınıflandırma algoritması olarak Rastgele Orman (RO) algoritması kullanılmıştır. Çalışmada seçilen test alanında 12 tarımsal ürün ile birlikte, orman yerleşim yeri, çim alanı ve çıplak toprak sınıfları oluşturulmuştur. Yapılan sınıflandırma işlemi sonucunda genel sınıflandırma doğruluğu % 76 olarak elde edilmiştir. Bu sınıflandırma içinde asmaların doğruluk oranları kullanıcı doğruluğu %76, üretici doğruluğu %94 olarak elde edilmiştir (Hernandez vd., 2020).

Campos vd. (2021) yapmış oldukları çalışmada İHA verileri ve PlanetScope görüntülerinden elde ettikleri NDVI değerlerinin, yersel yöntemle ölçülen asma bitki yüksekliği, bitki genişliği ve bitki hacmi ile olan ilişkisini araştırmışlardır. Elde ettikleri sonuçlar incelendiğinde İHA’dan üretilen NDVI değeri ile tüm değerlerde 0.84’ün üzerinde PlanetScope’dan üretilen değerlerde ise 0.48’in üzerinde korelasyon olduğu sonucuna ulaşılmıştır (Campos vd., 2021)

1.2. Tezin Önemi ve Amacı

Yukarıda verilen literatür araştırması incelendiğinde asmaların haritalanmasında farklı uydu sistemleri, farklı sınıflandırma yaklaşımları ve farklı sınıflandırma algoritmaları kullanılmaktadır. Ancak PlanetScope görüntüleri kullanılarak yapılan çalışma sayısı çok azdır.

PlanetScope uyduları Planet Laboratuvarları tarafından geliştirilen uydu sistemleridir. Her PlanetScope uydusu bir Küp-SAT 3U (10 cm x 10 cm x 30 cm) formu şeklindedir. Yaklaşık 180 uydudan oluşan eksiksiz PlanetScope takımı yıldızı, her gün Dünya’nın tüm kara yüzeyini görüntüleyebilecek kapasitedir. PlanetScope uyduları ile yeryüzünün her gün 3 m konumsal çözünürlükte görüntüsü çekilmektedir. Bu özelliğinden dolayı bu uydular tarımsal uygulamalar için büyük bir fırsattır.

Birçok tarım ürünü olduğu gibi asmalarda yetiştirilen üzümün rekolte tahminlerinin yapılması, sulama yönetiminin gerçekleştirilmesi, hastalıklı alanların izlenmesi, çiftçi kayıt sisteminin oluşturulması ve düzenli olarak güncellenmesi gibi hassas tarım uygulamaları açısından son derece önemlidir. Bu işlemlerin

gerçekleştirilebilmesi için öncelikle asma parsellerinin tespit edilmesi gerekmektedir. Bu kapsamda uzaktan algılama yöntemlerinin geçmiş yıllarda yapılan çalışmalarda farklı uydu sistemleri üzerindeki başarısı kanıtlanmıştır.

Bu tez çalışmasının ana hedefi PlanetScope uydu görüntülerinin asmaların tespit edilmesindeki başarısının araştırılmasıdır. Bu kapsamda Manisa ili içinde asmaların yoğun olduğu bir alan örneklem alan olarak seçilmiştir. Seçilen alana yönelik PlanetScope Görüntüleri indirilmiştir. İndirilen görüntülere piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımları uygulanarak PlanetScope görüntülerinden asma alanlarının tespit edilme başarısı belirlenmiştir. Piksel tabanlı sınıflandırma işleminde En Çok Olabilirlik (EÇO), Rastgele Orman (RO), Destek Vektör Makineleri (DVM) algoritmaları kullanılmıştır. Nesne tabanlı sınıflandırma işleminde RO, DVM, K-En Yakın Komşuluk (K-EYK), Karar Ağaçları (KA), Naives Bayes (NB) algoritmaları kullanılmıştır.

Bu tez çalışması kapsamında aşağıdaki sorulara cevap aranmaktadır:

- PlanetScope uyduları asmaları tespit etmede kullanılabilirliği nedir?
- Hangi sınıflandırma yaklaşımında (piksel tabanlı, nesne tabanlı) asmalar daha hassas şekilde tespit edilebilmektedir?
- Farklı sınıflandırma algoritmalarının asmaların tespit edilmesindeki başarısı nedir?

1.3. Tezin Yapısı

Bu tez çalışmasının giriş bölümünde tezin kapsamı literatürle olan ilişki, tezin önemi, araştırma soruları ve tezin yapısı hakkında bilgiler verilmiştir. Tezin ikinci bölümünde uzaktan algılamanın kuramsal temelleri anlatılmıştır. Üçüncü bölümünde çalışma alanı tanıtılmıştır. Dördüncü bölümde çalışma kapsamında kullanılan veri setleri tanıtılmıştır. Beşinci bölümde çalışma kapsamında uygulanan yöntemler anlatılmıştır. Altıncı bölümde tezin bulguları sunulmuştur. Yedinci bölümde elde edilen bulgular tartışılmıştır. Tezin sekizinci bölümünde ise tezle ilgili sonuç ve öneriler verilmiştir.


2. UZAKTAN ALGILAMANIN KURAMSAL TEMELLERİ

Bu bölümde uzaktan algılamanın temelleri ile ilgili bilgiler alt başlıklar halinde verilmiştir.

2.1. Elektromanyetik Enerji

Elektromanyetik enerji/ışınım, c ışık hızı ile harmonik dalgalar şeklinde hareket eden tüm enerji türleridir. Harmonik dalgalar ise periyodik ve eşit halde hareket eden dalgalardır. Elektromanyetik enerji türlerinden sadece bir tanesi görünür ışıktır. Bunun dışında mor ötesi, Radyo dalgaları, X-ışınları, ısı vs. farklı dalgalarda vardır.

Elektromanyetik dalgalar birbirine ve yayılma doğrultusuna dik olan Manyetik (M) ve Enerji (E) alanlarından oluşmaktadır. Tüm elektromanyetik enerji ışık hızında ($c = 3 \times 10^8$ m/s), hareket etmektedir. Tanecik ve dalga modeli Şekil 2.1’de açıklanmaktadır.



Şekil 2.1. Elektromanyetik Salınım


Elektromanyetik ışıınım maddenin herhangi bir hali ile (katı, sıvı, gaz) temas ettiği zaman doğrultu, şiddet, polarizasyon, faz ve dalga uzunluğu gibi faktörler açısından pek çok değişikliğe maruz kalır. UA çalışmalarında bu değişiklikler tespit edilerek kaydedilir. Bu işlemler sonucunda elde edilen görüntüler ve diğer veriler, her cismin özelliğinin belirlenmesi için uzaktan algılama çalışmaları kapsamında yorumlanır (Örmeci 1987).

Aslında uzaktan algılamanın temelini cisim-enerji arasındaki bu ilişkiler oluşturmaktadır. Ayrıca enerjinin dalga uzunluğu, cismin sıcaklığı ve bunlarla ilişkili olarak ışıyan enerji miktarı da UA’da önem arz etmektedir.

3.2. Elektromanyetik Spektrum

Elektromanyetik spektrum 3×10^8 m/s hızla hareket eden, dalga boyu nanometrelerden kilometrelere uzanan aralıklara sahip bir değer ortamıdır. Uzaktan algılama çalışmalarında genellikle ilgilenilen dalga boyları 0.30- 15 μm aralığındadır.

Elektromanyetik spektrum kullanım kolaylığı için belirli dilimlere bölünse de tam bir sınır söz konusu değildir. Her tip ışınım aralığının belirlenmesinde, uzaktan algılamanın farklı yöntemleri kullanılmıştır. Görünür ışınım spektrumun 0.4-0.7 μm aralığındaki çok küçük bir kısmında yer almaktadır. Elektromanyetik spektrumun değişik aralıklarında algılama yaparak elde edilen veriler ile yeryüzü hakkında pek çok farklı özellikler tespit edilerek yorumlanabilir. Uzaktan algılamada en çok kullanılan dalga boyları görünür (0.4–0.7 μm), kızılötesi (0.7–14 μm) ve mikrodalga (1–100 mm) ışınımıdır (Şekil 2.2). Elektromanyetik spektrumda kızılötesi ve görünür bölgede yapılan çalışmalarda enerjilerin algılanması için multispektral optik (Aster, Landsat, Sentinel vb.) algılayıcılar tercih edilirken, uzun dalga boylarında yapılan çalışmalarda aktif ya da pasif mikrodalga algılayıcılar kullanılmaktadır (Şekil 2.2).



Şekil 2.2. Elektromanyetik Spektrum

Uzaktan algılama sistemleri elektromanyetik ışınımın kullanıldığı dört temel bileşenden oluşmaktadır (Curran, 1985).

Elektromanyetik dalganın spektrumdaki yeri, frekansı ya da dalga boyuyla belirlenir. Frekans (ν) bir saniye içerisinde herhangi bir noktadan geçen dalga sayısını, dalga boyu (λ) ise iki dalga tepesi (ya da çukuru) arasındaki mesafeyi ifade etmektedir.

Bu sebeptendir ki dalga boyu ve frekans, ters orantılıdır.

$$\nu\lambda = c$$

Burada c ışık hızıdır. Elektromanyetik dalgalar için enerji ifadesi:

$$E = hv = h \frac{c}{\lambda}$$


şeklindedir. Öyleyse, elektromanyetik dalganın frekansı arttıkça enerjisi de artar diyebiliriz. Bir başka deyişle, frekans arttığında dalga boyu azalacağından, dalga boyu azaldığında da enerjinin arttığını söyleyebiliriz (Şekil 2.2).

Elektromanyetik spektrumun farklı bölgelerinde, değişik yeryüzü özellikleri kaydedilmektedir. Yapılan uzaktan algılama çalışmalarında ve algılayıcı tasarımlarında kullanılan uydu görüntülerinin seçiminde, elektromanyetik spektrumun algılama bölümleri önemli rol oynamaktadır (Musaoğlu 1999).

3.3. Elektromanyetik Enerjiye Atmosferik Etkiler

Işınım kaynağı aktif ya da pasif olsun, uzaktan algılamada algılanan tüm ışınlar atmosferde belirli bir yol almaktadır. Kaynaktan çıkan ve algılayıcıya ulaşan ışınlar bu yolu kat ederken atmosferden geçmektedir (Sunar vd., 2011).

Elektromanyetik enerji atmosfere girdiğinde, çeşitli yoğunluk ve geçirgenliğe sahip su moleküllerinin, parçacıkların ve atmosferik gazların varlığı nedeniyle emilim, kırılma ve saçılma etkisi altında olacaktır. Bazı elektromanyetik dalga frekansları tamamen emilirken, bazıları dağılabilir, enerjisi azalabilir ve bazıları hiçbir kayıp olmadan iletilebilir. Bu taban, elektromanyetik dalganın uzunluğuna ve mevcut atmosfer koşullarına bağlıdır. Sistemin güvenilirliği, böylece “atmosferik pencere” terimini oluşturan atmosferik etkileşimlerle sınırlıdır. Belli dalga boylarının kayıpsız olarak iletileceği eşsiz bant aralıkları Şekil 2.3’de gösterildiği şekildedir.



Şekil 2.3. Elektromanyetik enerjiye atmosferik etkiler

Absorpsiyon, elektromanyetik radyasyonun atmosferle etkileşime girdiği anda meydana gelir. Bu olay atmosferdeki moleküllerin çeşitli dalga boylarında enerjiyi absorbe etmesine neden olur. Ozon, karbon dioksit ve su buharı, radyasyonu emen üç ana atmosfer bileşenidir. Ozon aslında dünya sağlığı için önemli bir görev yaparak güneşten ultraviyole radyasyonu emmeye yaramaktadır. Karbondioksit, atmosferin içindeki bu ısının yakalanmasını sağlayan tayfin uzak kızılötesi kısmında radyasyonu güçlü bir şekilde alma eğilimindedir. Atmosferdeki su buharı ise gelen uzun dalga kızılötesi ve kısa dalgalı mikrodalga radyasyonu (22 μm ve 1 m arasında) emer. Alt atmosferdeki su buharının varlığı, yerin konumundan lokasyona ve yılın farklı zamanlarına göre büyük ölçüde değişir. Bir çölün üzerindeki hava kütlesi, enerjiyi emmek için çok az su buharına sahip olurken, tropik bölgeler yüksek neme bağlı olarak yüksek su buharı yoğunluğu taşımaktadır (Esemen 2011).

Saçılma, atmosferde bulunan parçacıklar veya büyük gaz molekülleri ile etkileştiğinde ve elektromanyetik radyasyonun orijinal yolundan yeniden yönlendirilmesine neden olduğunda meydana gelir. Ne kadar saçılma meydana gelirse, radyasyonun dalga boyu, parçacık veya gaz miktarı ve radyasyonun atmosferden geçtiği mesafe gibi çeşitli faktörlere bağlıdır. Üç tip saçılma vardır;

Rayleigh saçılması: Parçacıkların küçük toz veya azot ve oksijen molekülleri gibi radyasyonun dalga boyuna göre çok küçük olduğu zaman, kısa dalga boylarının daha uzun dalga boylarından daha çok dağılmasına sebep olmaktadır.


Mie saçılması: Parçacıkların, Rayleigh saçılmasından etkilenenlere göre daha uzun dalga boylarını etkileme eğiliminde olan toz, duman ve su buharı gibi radyasyon dalga boyu ile hemen hemen aynı büyüklükte olduğunda, atmosferin alt kısımlarında meydana gelmektedir.

Non-selektif (Seçici olmayan) saçılma: Parçacıklar, su damlacıkları ve büyük toz parçacıkları gibi radyasyonun dalga boyundan çok daha büyük olduğunda meydana gelir, bu da tüm dalga boylarının saçılmasıyla sonuçlanmaktadır.

3.4. Cisimlerin Spektral Yansması


Cisimlerin uzaktan algılama ile ifade edilebilmelerinin sebebi ana spektral özelliklerinin farklı olmasıdır. Cisimler enerjiyi farklı yansıtma spektral yansıtım eğrileriyle gösterilmektedir. Spektral bantların her biri elektromanyetik spektrumun belirli bir aralığına duyarlıdır. Spektral yansıtım özellikleri belli spektral aralıklarda ayırt edilebilir biçimde farklılık gösteren cisimler o aralıklara duyarlı uzaktan algılama görüntülerinde farklı renklerde görünürler. Bu doğrultuda cisimlere ait spektral yansıtım özelliklerinin biliniyor olması, spektral bant seçiminde önemlidir (Ekercin 2007; Sunar vd., 2011).

Yansıtılma: Tüm ışının belli bir miktarı objeden geri yansır ve yüzey pürüzlülüğü ve ışının geliş açısıyla ilişkili olarak farklı şekilde saçılmaktadır (Şekil 2.4).




Şekil 2.4. Cisimden yansıyan ışınım örneği

Yutulma: Objeye gelen toplam ışınımın belli bir miktarı çevredeki elektron ve moleküler tepkimeler sebebi ile soğrulur, bu ışınımın belli bir miktarı çoğunlukla uzun dalga boylarında geri yansır, bir kısmı ise yutularak objenin ısınıp ısıtmasını sağlar (Şekil 2.5).




Şekil 2.5. Cisimden tarafından yutulan ışınım örneği

Geçirilme: Gönderilen enerji bazen su vb. maddelere nüfuz edebilir. Maddeye gelen saydam ışınımın bir kısmı maddeden geçip diğer ortama iletelebilmektedir (Şekil 2.6) (Marangoz, 2018).



Şekil 2.6. Cisimden geçirilen ışınım örneği

Bütün maddeler yansıtma bakımından birbirinden farklı özelliklere sahiptir. Bu özellikler spektral yansıtma eğrisi olarak adlandırılan bir egride gösterilmektedir. Eğri, ışının sahip olduğu dalga boyu ile ilişkili olarak yüzeyden yansıyan ve yüzeye gelen toplam ışının yüzdesini ifade etmektedir. Cisimlerin spektral yansıtma katsayısı ölçülüp spektral yansıtma eğrileri oluşturulur. Kullanılacak algılayıcının ve uzaktan algılamada çalışılacak alanın seçiminde bu eğrilerden faydalanılır. Bu açıdan cisimlerin spektral yansıtma özelliklerinin biliniyor olması, ihtiyaç duyulan bandın seçiminde önem arz etmektedir (Sunar vd., 2011).




Şekil 2.7. Cisimlerin Spektral Yansıtması

Spektrometre cihazları ile değişik özelliklere sahip yüzeylerin spektral imzaları oluşturulabilir. Bu sayede herhangi bir spektral bantta obje yüzeyinden yansıyan elektromanyetik radyasyon algılanır. Bu işlem her bant için ölçülerek, tüm dalga boylarında spektral imza elde edilebilir. Herhangi bir materyal için, yansıyan (emilen veya iletilen) güneş ışınımının miktarı dalga boyu ile değişecektir. Maddenin bu önemli özelliği, belirli bir dalga boyu için tepki değerlerine göre farklı kapak tiplerini ayırmamızı sağlar. Belli bir arazi örtüsünün spektral imzası, tepki özelliklerinin dalga boyu ile ilişkisi olarak tanımlanmaktadır (Sunar vd., 2011). Her bir maddenin kendine özgü bir spektral

yansımaya sahip olmasına rağmen, en sık gözlenenler toprak, su ve yeşil bitki örtüsünün 3 benzer yansıtma özelliği altında toplanmıştır (Şekil 2.7).


3.4.1. Bitkilerin spektral yansımaları

Genel olarak, sağlıklı bitki örtüsü, görünür bölgede çok iyi bir elektromanyetik enerji emicidir. Klorofil, 0.45 (mavi) ve 0.67 μm (kırmızı) dalga boylarında ışığı güçlü bir şekilde emer ve yeşil ışıktaki güçlü bir şekilde yansıtır, bu nedenle gözlerimiz sağlıklı bitki örtüsünü yeşil olarak algılar (Şekil 2.8). Sağlıklı bitkiler, yakın kızılötesinde 0,7 ila 1,3 μm arasında yüksek bir yansıtma oranına sahiptir. 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 (Sunar vd., 2011).



Şekil 2.8. Bitkilerin Spektral Yansımaları

Yaprakların içyapısı yakın kızılötesinin yansıtım derecesini kontrol etmektedir. Kaynaktan çıkan enerjinin neredeyse yarısı yaprak tarafından yansıtılır, kalan kısmının çoğu geçirilir ve çok az kısmı da yutulur.



Şekil 2.9. Klorofil Spektral Yansıması

Bitkilerin toplam nem muhteviyatı, gelen ışınımın ekseriyeti yaprak içerisindeki su tarafınca yutulacak ve geri kalanı yansıyacak şekilde orta kızılötesi yansıtmayı kontrol etmektedir. 0.98–1.20 μm arası dalgı boylarında çalışan algılayıcılar ile bitkilerin hücre yapısını değıştiren bitki hastalıklarının tespit etmek mümkündür (Şekil 2.8).

Kısacası, bitkilerin spektral yansıması; yakın kızılötesi aralığında hücre yapısına, orta kızılötesi aralığında nemliliğine ve görünür kısımda ise klorofil pigmentlerinin yansıma ve yutmasına bağlıdır (Şekil 2.9) (Sunar vd., 2011).

Bitkilerde yansıtmayı etkileyen faktörlerin bitkinin kendisinden kaynaklanabileceğı gibi bazı dış etkenlere de bağlı olması söz konusudur. Bunlar; yaprağın morfolojik yapısı, yaprakların yaşı, bitkilerin büyüme dönemleri, bitkilerin yaprak yapısı, yapraklardaki su kaybı, yüksek tuzluluk, besin elementi eksiklikleri, hastalık ve zararlılardır (Karadağ ve Taşaltın 2016).

Sağlıklı ve yeşil bitkilerin spektral yansıma eğrileri genellikle birbirini takip eden tepe ve çukurlar şeklindedir. Spektral grafikte görünen bölgedeki çukurlar, bitki yapraklarında bulunan pigmentler sebebi ile oluşur. Çünkü klorofil a ve klorofil b olarak isimlendirilen maddeler yaklaşık 0,45 ve 0,67 μm değerlerine, merkezlenmiş dalgı boyu bantlarındaki enerjiyi büyük oranda soğurur (Senanda, 1986). Mavi ve kırmızı enerjinin bahsedilen bu değerlerde bitki yapraklarında yutulması ve yeşil enerjinin de aynı oranda yansıması, insan gözünün sağlıklı bir bitkiyi yeşil renkte görmesini sağlar. Eğer bitkiler beklenen gelişim ve verimini engelleyen bazı zorlamalara maruz kalıyorsa klorofil

üretimi, azalmış ya da olmuyor demektir. Böylesi durumlarda, kırmızı ve mavi bantlarda daha az klorofil soğrulduğundan dolayı sağlıklı yeşil bitki renginde değişimler tespit edilecektir (Kavak, 1998).

3.5. Uzaktan Algılama Sistemleri

Uzaktan algılama, belirli bir mesafeden (tipik olarak uydu veya uçaktan) yansıyan ve yayılan radyasyonunu ölçerek bir alanın fiziksel özelliklerini algılama ve izleme sürecidir. Başka bir deyişle, fiziksel temas olmadan bir bölgenin fiziksel özelliklerini tespit etmek ve izlemek için Dünya'nın karasal, atmosferik ve sucul ekosistemlerinden yayılan ve yansıtılan elektromanyetik (EM) radyasyonu örnekleyen bir jeo-uzamsal teknoloji türüdür. Uzmanlar özel kameralar yardımı ile Dünya hakkındaki şeyleri "algılamasına" yardımcı olan uzaktan algılanan görüntüleri toplar (Sunar vd., 2011).

Modern uzaktan algılamanın en eski uygulamaları, 1840'larda topografik haritalama amacıyla balonlardan alınan dünya yüzeyinin ilkel fotoğraflarından oluşuyordu. Modifiye uçaklar kullanılarak sistematik hava fotoğrafçılığı, Birinci Dünya Savaşı sırasında ve Soğuk Savaş sırasında askeri gözetleme ve keşif amaçları için geliştirildi. Uzaktan algılama, 1909 yılında Wilbur Wright tarafından bir uçaktan ilk kez sıralı bir şekilde Hava Fotoğrafı çekimi ile başlamıştır.

1960'larda uzay programının ortaya çıkmasıyla birlikte, Dünya gözlemi ve Nimbus ve Landsat gibi hava uyduları üzerindeki enstrümantasyon, askeri, sivil ve araştırma amaçlı çeşitli verilerin küresel ölçümlerini sağladı. Çok yüksek çözünürlüklü görüntüleri toplamak için inşa edilen ilk ticari uydu olan IKONOS, Lockheed Martin tarafından görevlendirildi, 1999'da fırlatılmıştır.


Uydulardan alınan görüntüler sayesinde yeryüzü küresel bir ölçekte gözlemlenebilmekte ve birçok sorunun bertaraf edilmesinde güncel, ekonomik ve hızlı çözümler sunmaktadır.

Uzaktan algılama teknolojisi, tarım, 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 kullanılır (Sunar vd., 2011).

3.5.1. Uzaktan algılama verilerinin elde edilmesi

Uzaktan algılamada veri elde edilmesinde kaynaktan çıkan enerji yeryüzü cisimleri ile etkileşime girerek gelen enerjiyi belirli bir iletim yolu ile algılayıcı sensöre iletir. Bu sensörlerde kayıt edilen görüntüler yeryüzündeki istasyonlara gönderilir.

Kullanıcılar yeryüzündeki istasyonlardaki görüntüleri işleyerek amaçlarına yönelik olarak kullanırlar (Sunar vd., 2011) (Şekil 2.10).



Şekil 2.10. Uzaktan algılamanın çalışma prensibi

Enerji Kaynağı (A): Doğal veya yapay bir kaynak ile hedefe enerji gönderilmektedir. Bu kaynak hem hedefi aydınlatır hem de hedefe elektromanyetik enerji göndermektedir. Pasif uydu sistemlerinde tek enerji kaynağı güneştir, fakat pasif radar uydu sistemlerinin kendi enerji kaynakları kendileridir ve ürettiği elektromanyetik enerjiyi hedefe gönderir.

Işınım ve Atmosfer (B): Doğal veya yapay kaynaktan çıkan enerji hedefe ve alıcıya doğru kat ettiği yolda atmosfer ortamından geçer ve bazı diğer etkileşimlere maruz kalır.

Hedef ile Etkileşim (C): Elektromanyetik dalga atmosfer ortamından geçtikten sonra, hedefe vardığında hem ısınım hem de hedef özellikleriyle ilişkili olarak farklı etkileşimler oluşturmaktadır.

Enerjinin Algılayıcı Tarafından Kayıt Edilmesi (D): Algılayıcı, hedefle etkileşiminde yayılan ve saçılan enerjiyi algılayarak ilgili veriyi kaydeder.

Verinin İletimi, Alınması ve İşlenmesi (E): Algılayıcının kaydettiği veri, görüntüye dönüştürülerek işlenmek için uydu yer istasyonlarına iletilir.

Yorumlama ve Analiz (F): İşlenen görüntü görsel, dijital ve elektronik tekniklerle zenginleştirilir, analiz edilir ve nicel sonuçlara ulaşılacak veri seti elde edilir.


Uygulama (G): Elde edilen veri setlerinden bilgi çıkartılarak belirli sonuçlara ulaşılır. Sonrasında üretilen sonuçlar, başka veri setleriyle birleştirilerek kullanılabilir.

3.5.2. Algılayıcı tipleri

Uzaktan algılama biliminde kullanılan ve geliştirilen algılayıcılar pasif ve aktif sistemler olmak üzere iki temel gruba ayrılmaktadır (Sunar vd., 2011):

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

2-Aktif Sistemler: verileri toplamak için dahili uyaranlar kullanır, nesneleri ve alanları taramak için enerji yayar ve bunun üzerine bir sensör hedeften yansıyan enerjiyi ölçer. RADAR ve LiDAR, bir nesnenin konumunu, yönünü ve hızını belirlemek için emisyon ve geri dönüş arasındaki zaman gecikmesini ölçen tipik aktif uzaktan algılama araçlarıdır. Toplanan uzaktan algılama verileri daha sonra çeşitli tescilli ve açık kaynak uygulamalarında bulunan uzaktan algılama donanımı ve bilgisayar yazılımı ile işlenir ve analiz edilir (Şekil 2.11).



Şekil 2.11. Uzaktan algılamada kullanılan aktif ve pasif sistemler (http-2)

3.5.3. Uydu yörüngeleri ve tarama alanı

Uyduların dünya veya başka bir cisim etrafında düzenli olarak izlediği yola yörünge adı verilir. Yörüngeler döndükleri yönler, yüksekliklerine ve konumlarına göre üç sınıfa ayrılmaktadır (Sunar vd., 2011):

1- Alçak Yörünge Uyduları: Dünya yüzeyine nispeten yakın bir yörünge. Normalde dünyaya göre 160 km -1000 km arası yükseklikte konumlanır. Bu diğer yörüngelerle karşılaştırıldığında düşüktür, ancak yine de Dünya yüzeyinin çok üzerindedir. Dünya'ya olan yakınlığı alçak yörüngeli uyduları birkaç nedenden dolayı yararlı kılmaktadır. Yüzeye yakın olması, daha yüksek çözünürlüklü görüntüler çekmesine izin verdiği için, uydu görüntüleme en yaygın olarak kullanılan yörünge.

2- Orta Yörünge Uyduları: Dünyaya göre 5000-15000 km yükseklikte bulunan uydulardır. Kapsama alanları Alçak Yörünge Uydularına oranla 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.

4-Tarama Alanı: Uydular yörüngesinde ilerlerken, algılayıcılar yeryüzünün bir bölümünü taramaktadır. Uydu bu yörünge boyunca ilerlerken taradığı bölgeye "tarama alanı" denmektedir.

3.5.4. Uydu Görüntüleri

Uzaktan algılanan görüntüler yer istasyonlarına indirildiklerinde 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 (Sunar vd., 2011).

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

Uydu görüntülerini tanımlayan dört farklı çözünürlük bulunmaktadır. Bunlar, konumsal çözünürlük, radyometrik çözünürlük, spektral çözünürlük ve zamansal çözünürlüktür (Ekercin 2007).

Konumsal Çözünürlük: Bu çözünürlük türü genellikle tek bir pikselin bir tarafının uzunluğu olarak ifade edilir. Örneğin Landsat 8'in, multispektral bantları 30 metre konumsal çözünürlüğe sahipken Sentinel 10 m konumsal çözünürlüğe sahiptir. Başka bir deyişle, 30 metre konumsal çözünürlüğe sahip bir görüntü, tek bir pikselin zeminde 30 m x 30 m genişliğinde bir alanı temsil ettiği anlamına gelir.

Radyometrik Çözünürlük: Piksellerin düzenlenmesi bir görüntünün konumsal yapısını tanımlarken, radyometrik özellikler bir görüntüdeki gerçek bilgi içeriğini tanımlar. 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 tanımlar. Bir sensörün radyometrik çözünürlüğü ne kadar ince olursa, yansıyan veya yayılan enerjideki küçük farklılıkları tespit etmede o kadar hassas olur. Radyometrik çözünürlük yeryüzünden yansıyan ışınımın bantlarda kayıt edildiği bit sayısı ile ilgili bir kavramdır. Örneğin Landsat 5 uydu görüntüsü bantları 8 bitlik radyometrik çözünürlüğe sahiptir. Bu uydu görüntüsünün bir bandındaki gri renk seviyesi 0 ile 255 (2^8-1) arasında değişmekte ve 256 (2^8) adet renk bilgisi içermektedir. Landsat 8 spektral bantları 16 bitlik radyometrik çözünürlüğe sahiptir. Bu uydu görüntüsünün bir bandında 0'dan 65535'e ($2^{16}-1$) kadar farklı gri renkler bulunur ve toplam gri renk sayısı 65536'dır (2^{16}).

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 ve Landsat 8'de toplam 11 bant bulunmaktadır. Örneğin, MODIS (Orta Çözünürlüklü

Görüntüleme Spektrometresi), Landsat 8'den daha yüksek spektral çözünürlüğe sahiptir, çünkü 0,4 ila 14 mikrometre dalga boylarını kapsayan dar bir banda sahiptir.

Zamansal Çözünürlük: Bir algılayıcının yörünge üzerinde ilerlerken aynı alandan ikinci görüntüyü alma süresi ile ölçülür. Örneğin Landsat 8'in zamansal çözünürlüğü 16 gündür.

3.5.5. Görüntü 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 (Sunar vd., 2011).

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.

3.5.5.1. Geometrik düzeltme

Tüm ham havadan görüntüler, bir dereceye kadar geometrik bozulma içerir. Bu bozulmalar sensör konumundaki farklılıklar, görüntüler kaydedilirken dünyanın kendi eksenini üzerinde dönmesi, zemin eğriliği ve son olarak arazi etkileri (rölyef yer değiştirme) nedeniyle. Bazı bozulmalar öngörülebilirdir ve kolayca düzeltilebilirken diğerleri daha karmaşıktır ve verilerden kaldırılması zordur.

Farklı zamanlı görüntüler üzerinden analiz yapılırken veya farklı kaynaklardan üretilen verilerin ortak bir sistemde kullanılarak analiz yapılması gerektiğinde verilerin ortak bir koordinat sisteminde coğrafi olarak referanslanması gerekmektedir.

Coğrafi referanslandırma yapılmak istenildiğinde bir koordinat sistemine sahip bir veri katmanı veya sahada toplanan verilerin olması gerekir. Bilinen bir koordinat sistemine sahip bir katman kullanıyorsa, Yer Kontrol Noktalarını (YKN) belirlemek gerekir. Yer kontrol noktaları, 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 çalışılıyorsa, zaman içinde hareket etmemiş veya değişmemiş YKN'lerin seçilmesi gerekir. GNSS ile sahada yer kontrol noktaları da toplanabilir. Kontrol noktaları, veri kümeleri arasında bir bağlantı oluşturur ve görüntülerin coğrafi referanslanmasına yardım eder.

3.5.5.2. Radyometrik düzeltme

Piksel değerlerini kalibre etmek ve değerlerdeki hataları düzeltmek için radyometrik düzeltme yapılır. Süreç, uzaktan algılanan verilerin yorumlanabilirliğini ve kalitesini iyileştirir. Radyometrik kalibrasyon ve düzeltmeler, 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 hata nedeni ile ihtiyaç duyulabilir;

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

3.5.5.3. Görüntü keskinleştirme

Görüntü keskinleştirme, tek bir yüksek çözünürlüklü renkli görüntü oluşturmak için yüksek çözünürlüklü pankromatik ve daha düşük çözünürlüklü multispektral görüntüleri birleştirme işlemidir. Multispektral görüntülerin çoklu bantları ve daha yüksek derecede spektral çözünürlüğü vardır, ancak genellikle yüksek konumsal çözünürlükten yoksundur. Öte yandan pankromatik görüntüler yalnızca bir geniş bant yansıtma verisi, ancak daha yüksek konumsal çözünürlüğe sahiptirler. Bu işlemi, multispektral ve

pankromatik görüntüleri birleştirerek her iki görüntü türünün en iyisini, yüksek spektral çözünürlük ve yüksek konumsal çözünürlük sağlar. Günlük hayatta kullandığımız haritalama yazılımlarında kullanılan yüksek çözünürlüklü görüntülerin çoğu, bu yöntemle üretilir. Örneğin; Landsat 8'in multispektral bantları 30 m konumsal çözünürlüğe sahiptir fakat 15 m uzaysal çözünürlüğe sahip pankromatik bir bant da toplanabilir. Sentinel ise pankromatik bantı yardımı ile 10 m çözünürlüklü multispektral bant elde edilebilir.

3.5.6. Uydu Görüntülerinden Bilgi Çıkarma

Uydu görüntüleri raster formatta bulunan verilerdir. Bu verilerde her bir pikselde spektral yansıma değerleri saklanmaktadır. Yeryüzüne ait bilgi çıkarma işleminde bu piksel değerlerinden yararlanılmaktadır. Uydu görüntülerinde bilgi çıkarmak için görsel yorumlama ve dijital görüntü analizinden faydalanılmaktadır.

Görsel yorumlama işleminde, görüntüde yer alan şekillerin boyutu, şekli, rengi, dokusu, çevre objelerle olan ilişkileri uzman görüşlerinden faydalanılarak bilgi çıkarma işlemi yapılmaktadır. Bu yöntem ile bilgi çıkarmada alanında uzmanlaşmış personellere ihtiyaç duyulmaktadır. Görsel yorumlama insanın görüntü detaylarını algılayabildiği ölçüde başarılı bir yöntemdir. Geniş alanları kaplayan alanlara yönelik analizlerde çok uzun süreler alabilmektedir.

Dijital görüntü analizi geliştirilen algoritmalar aracılığı ile gerçekleştirilen bir görüntü analiz tekniğidir. En yaygın kullanılan dijital görüntü analizi teknikleri değişim saptama, aritmetik bant indeksleri ve uydu görüntüsü sınıflandırmadır. Değişim saptamada farklı tarihli görüntüler arasında meydana gelen değişimlerin belirlenmesi gerçekleştirilmektedir. Bu aşamada görüntü farkları alınarak değişimler ortaya konulmaktadır. Aritmetik bant işlemlerinde, uydu görüntüsüne ait bantların toplanması, çıkarılması, bölünmesi gibi işlemlerle yeryüzüne ait bilgiler çıkarılmaktadır. Bu kapsamda bitki indeksleri, mineral indeksleri, su indeksleri gibi spektral indeksler aritmetik bant işlemleri ile elde edilmektedir. Uydu görüntülerinden bilgi çıkarmada kullanılan en yaygın yöntem görüntü sınıflandırmadır. Görüntü sınıflandırma işlemi görüntü bantlarındaki benzer piksellerin gruplandırılması temeline dayanmaktadır. Görüntü sınıflandırma işlemi görüntülere piksel tabanlı ve nesne tabanlı olarak uygulanabilmektedir (Sunar vd., 2011).



3. ÇALIŞMA ALANI

Bu tez çalışması kapsamında asmaların haritalanması için Manisa ili Saruhanlı ilçesinde kalan ve asma yetiştiriciliğinin yoğun olarak yapıldığı bir bölge çalışma alanı olarak seçilmiştir (Şekil 3.1). Çalışma alanı Saruhanlı ilçesinin Hacırahmanlı, İshakçelesi, Nuriye ve Lütfiye mahalleleri ile Mütevelli, Develi ve Alibeyli mahalleleri arasında yer almaktadır ve yaklaşık 9 bin hektar büyüklüğündedir.


3.1. Çalışma Alanına Ait Genel Bilgiler

Konum: Çalışma alanı 27° 08' ve 29° 05' doğu boylamları ile 38° 04' ve 39° 58' kuzey enlemleri arasında yer alan Manisa ili sınırları içinde yer almaktadır. Manisa ili doğudan Uşak ve Kütahya'ya, batıdan İzmir, güneyden Aydın, kuzeyden Balıkesir, güneydoğudan Denizli illerine komşudur. Yüzölçümü 13 810 km² olan ilde yükselti değerleri 50 metre ile 850 metre arasında değişmektedir. İl merkezinden doğuya doğru bu yükselti değeri artış göstermektedir (http-2).

Yeryüzü Şekilleri: Manisa ilinin arazi yapısı oluk şekilli çukurlardan oluşmaktadır. Oluk şekilli çukurlar doğu-batı, kuzey-güney ve güneydoğu- kuzeybatı doğrultularında çatallanmaktadır. Bu oluklardan Gediz ovası ilin Egede bulunan kısmını boydan boya yarmaktadır. Gediz ovasının Akhisar ve Alaşehir kolları da il sınırının İç Batı Anadolu kenarı boyunca uzanmaktadır. İl topraklarının büyük bir kısmını oluşturan Kula- Gördes platosu bu kenarın doğusunda bulunmaktadır. İlin Ege denizine dikey olarak uzanan dağ sıralarında yer alan bölgesinde, dağlık ve sarp tepelik alanlar, dalgalı kesimler, taban topraklar ve düzlükler olmak üzere birbirinden kesin çizgilerle ayrılabilen üç değişik yeryüzü şekli vardır. Dağlık ve sarp alanlar ilin kuzey, güney ve doğusunda bulunmaktadır. Batıya gidildikçe yükseltisi azalan dağlar, dere ve çaylarla kesilmektedir. İlinin doğu bölgeleri, İç Anadolu geniş çanağı ile ege bölümünde yer alan Gediz ve Kumçayı ovaları arasında güneydoğu-kuzeybatı eksenli bir eşikte yer almaktadır. İlin güneyindeki Bozdağlar Gediz vadisi üzerine doğru, yani kuzeye yönlü dik inmektedir. Manisa ilinin genel yeryüzü şekilleri incelendiğinde, il alanın %54.3' ü dağlardan, %27.8'i platolardan ve %17.9'u ovalardan oluştuğu görülmektedir (http-2).



Çalışma Alanı Planet Scope Uydu Görüntüsü



Şekil 3.1. Çalışma alanının genel görünümü

İklim: Manisa ili farklı iklim özelliklerine sahiptir. İlde Akdeniz iklimi ve karasal iklim özellikleri birlikte görülmektedir. Ovalar ve ovaları çevreleyen vadilerde karasal nitelikli Akdeniz iklimi görülürken, yüksek dağlık bölgeler ve platolarda İç Anadolu'nun karasal iklim özellikleri hakimdir. Ovalarda görülen iklim, Akdeniz kara iklim tipi olarak da adlandırılır. İlde yaz aylarında sıcaklık değerleri yükselirken, kış aylarında yağışların yoğunlaştığı gözlemlenir. Ovaların çevresindeki bulunan dağların yükseltileri deniz etkisini kesecek kadar yüksek olmaması ve bu dağların denize dik olarak konumlanması nedeni ile ildeki deniz etkisi batıdan doğuya doğru azalır. Ovalık alanlarda denize yakınlığından dolayı yumuşak bir iklim görülürken, şehir merkezinde Manisa dağının etkisi nedeni ile daha sert bir iklim görülür. Manisa dağının çıplak ve sarp alanlar yazın yakıcı, kışın dondurucu bir hava koşuluna sahiptir. İlde yaz ayları oldukça sıcak geçmektedir. İl merkezinde yılda ortalama olarak 162 gün yaz günüdür. Yılda ortalama 26 gün sıcaklık sıfırın altında düşebilmektedir. İlin yıllık ortalama sıcaklığı 17.5°C civarlarındadır (http-2).

Manisa ilinin Batı Anadolu bölgesi, Akdeniz iklim tipinin yağış özelliklerini taşır. Bu bölgede yazlar kurak geçerken, kış aylarında yoğun yağışlar görülür. Bölgenin ortalama 82 günü yağışlı geçmektedir. Bölgeye düşen ortalama yağış miktarı 713.6 mm'dir. İl sınırları içindeki yeryüzü şekilleri değişkenlik gösterdiğinde dolayı ovalar ve vadilerde nadiren, yüksek kesimlerde bu alanlara göre daha fazla şekilde kar yağışı görülebilmektedir (http-2).

Bitki Örtüsü: Manisa ilinin coğrafi özellikleri bölgede farklı bitki türlerinin yetişmesine neden olmaktadır. İlde karasal ve Akdeniz iklimine ait bitki türlerini görmek mümkündür. İl topraklarının %46'sı maki ve ormanlardan oluşmaktadır. Makiler özellikle dağlık alanların kuzey ve batı yamaçlarında yoğunlaşmıştır. İlde 1000 m üzerindeki yükseltilerde bulunan ormanlarda ardıç, ahlat, meşe, çınar, dişbudak, karaağaç, karaçam ve kızılçam gibi ağaç türleri yer almaktadır. İl alanının %39.1'i ekili ve dikili arazi tarım arazilerinden oluşur. Asma ve zeytin alanları tarım alanlarında önemli bir yeri kaplar. İl sınırları içinde yaklaşık 4 milyon civarında zeytin ağacı ve 56 bin hektara yakın asma alanı mevcuttur. İlin %6.6'sı çayır ve meralardan, %8.3'i tarıma elverişsiz topraklardan oluşur (http-2).

3.2. Çalışma Alanında Asma Yetiştiriciliği

Asma, iklim ve toprak özellikleri bakımında çok seçici olmaması, çoğaltma yöntemlerinin kolay olması ve farklı amaçlar için kullanılabilmesinden dolayı dünyadaki en yaygın kültür bitkilerinden biridir. 2019 yılında dünyada asma alanlarından üretilen toplam 10 milyon ton yaş üzüm ihracatının 1,7 milyon tonu Türkiye tarafından yapılmıştır. Aynı yıl dünyada toplam yaklaşık 3 milyon tonluk kuru üzüm ihracatı yapılmış olup, bunun 2,1 milyon tonu (%73,0) Türkiye tarafından gerçekleştirilmiştir. Ülkemizde 2019 yılında yaklaşık 4,1 milyon dekarlık bir alanda üzüm üretimi gerçekleşmiştir. Üretilen üzümü bölgelere göre incelendiğinde, Akdeniz’de ilk turfanda, Marmara’da sofralık ve şaraplık, Orta Anadolu ve Güneydoğu Anadolu’da şaraplık, sofralık, çekirdekli kurutmalık ve Ege’de çekirdeksiz üzüm yetiştiriciliği yoğun olarak yapılmaktadır. Üretim çeşitliliğine göre tüm asma alanları incelendiğinde Manisa %19,9’luk pay ve 809 bin dekarlık alan ile Türkiye’de birinci sırada yer almaktadır (http3).

Manisa yöresinde asma tarımı faaliyetlerinin antik çağa kadar uzandığına dair bilgi ve buluntulara ulaşmak mümkündür. Gediz ırmağından beslenen ovaya Antik Çağda "Lidya'nın Altın Ovası" veya "Üzüm Ovası" ismi verilmektedir. Asma yetiştiriciliği bahsi geçen çağlarda yaygın olarak yapılan mermer işlerinde görülmektedir (http-3).

Yakın zamanlı tarım sayımları incelendiğinde 1913 yılında Manisa Saruhan civarında 226 600 dönüm asma alanında 92 573 ton üzüm elde edildiği ve aynı sayım yılında 16 459 ton kuru üzüm olduğu görülmektedir. Manisa’da 1928 yılında il genelinde 13 340 ton kuru üzüm üretimi yapıldığı tespit edilmiştir. 1931 yılına gelindiğinde ildeki üzüm üretiminde don ve Filoksera (asma köklerinde zarar yaparak asmayı kurutan bir bağ zararlısı) gibi nedenlerden dolayı üzüm üretimin en düşük seviyelere indiği görülmektedir (http-3).

Türkiye geneli kurutmalık ve sofralık üzüm üretimi incelendiğinde Manisa ili üretimde Türkiye birincisidir. TÜİK verilerine göre, Türkiye’de üretilen kurutmalık üzümün % 85’i, sofralık üzümün % 20’si Manisa’da üretilmektedir. İl tarım alanının yaklaşık %16’sı üzüm yetiştirmek için asmalardan oluşmaktadır. Manisa’da yapılan tarımsal üretim incelendiğinde, Asma yetiştiriciliği ilinin en önemli gelir kaynağını oluşturmaktadır. Manisa’da yaklaşık 50 bin aile, 777 404 dekar alanda asma

yetiştiriciliğinden geçimini sağlamaktadır. Manisa ilçelerine ait üretilen üzümlerin alansal dağılımı Tablo 3.1’de verilmiştir. Tablo incelendiğinde Manisa ilinde en çok üzüm yetiştirilen ilçeler sıralamasında yaklaşık 200 bin dekar ile Alaşehir gelmektedir. Alaşehir ilçesini 110 bin dekarla Salihli ilçesi izlemektedir. Salihli ilçesinden sonra 90 bin dekar ile Sarıgöl ve Saruhanlı ilçeleri gelmektedir (http-3).

Tablo 3.1. *Manisa ilinde ilçe bazında asma alanları*

İlçe	Asma Alanı (dekar)
AHMETLİ	50 000
AKHİSAR	19 000
ALAŞEHİR	200 160
DEMİRCİ	6 405
GÖLMARMARA	23 200
GÖRDES	4 200
KIRKAĞAÇ	4 950
KÖPRÜBAŞI	339
KULA	5 000
SALİHLİ	110 000
SARIGÖL	90 000
SARUHANLI	90 000
SELENDİ	1 000
ŞEHZADELER	65 000
SOMA	500
TURGUTLU	82 650
YUNUS EMRE	25 000
TOPLAM	777 404

Manisa ilinde farklı türlerde üzüm yetiştirilmektedir. İlde en yaygın yetiştirilen üzüm çeşidi %90’lık oranla sultaniye üzümüdür (Şekil 3.2). Sultaniye üzümü Sultani çekirdeksiz üzüm olarak adlandırılmakta ve Dünyaca tanına en önemli üzüm çeşidi olma özelliğini taşımaktadır. “Manisa’da üretilen Çekirdeksiz Üzüm isminin kökeni, Osmanlı Devletinde Padişahlık yapmış Fatih Sultan Mehmet ve Kanuni Sultan Süleyman gibi önemli isimlerin de içinde yer aldığı Şehzadelerin yetiştiği Manisa’da, "Sultanların Üzümü - Sultanlara Layık" olarak Sultani ismini almış olmasıdır”. Geri kalan % 10’luk alanda ise Alfonselavalle, Crimson seedles, Razakı, Süperiorseedles, Earlysweet, Trakya İlkeren, Red Globe üzümleri sofralık olarak yetiştirilmektedir (http-3).



Şekil 3.2. *Manisa’da yetiştirilen Sultani üzümü*

4. PLANETSCOPE UYDULARI

Tez çalışması kapsamında çalışma sahası olarak seçilen alanda asmaların haritalanması için PlanetScope uyduları kullanılmıştır. Kullanılan bu uydu sistemine ait bilgiler aşağıda verilmiştir.

PlanetScope yörüngede bulundurduğu 180 uydu ile yeryüzünün tamamına ait günlük görüntü elde etme kapasitesine sahip bir takımyıldızı uydu sistemidir. Dünya'nın tüm kara kütesinin günlük 3-5 metre çözünürlüklü görüntülerini toplayarak tarihin en büyük ticari uydu filosunu oluşturmaktadır. Bu uydu filosu Planet Lab. tarafından işletilmektedir. PlanetScope uyduları küp-SAT olarak adlandırılan küp uydulardır (Şekil 4.1). Uydular 10 cm x 10 cm x 30 cm (yükseklik x genişlik x uzunluk) boyutlarındadır.



Şekil 4.1. Örnek bir PlanetScope uydusu

PlanetScope uyduları üzerinde taşıdıkları sensörlerle kırmızı, yeşil, mavi ve yakın kızılötesi olmak üzere dört farklı multispektral bantta görüntü kayıt etmektedir. Uydu çektiği görüntülerde konumsal çözünürlüğü 3.7-4.1 metre görüntüler elde etmektedir. Bu görüntüler kullanıcılara 3 m konumsal çözünürlüğe örneklenerek sunulmaktadır. Çekilen görüntülerin radyometrik çözünürlüğü 16 bittir. Uydu ticari bir uydu olmakla beraber araştırmacılara güncel tarihten altı ay öncesine kadar sistemde kayıtlı olan görüntüleri ücretsiz olarak sunmaktadır. Uydunun sunmuş olduğu konumsal çözünürlükle arazi kullanım/arazi örtüsü haritalama, değişim saptama, tarımsal ürün izleme gibi uygulamalar kolaylıkla gerçekleştirilebilmektedir. Uydular üzerinde farklı sensör takılabilmektedir. PS2, PS2.SD ve PSB.SD olmak üzere uydu filosunda 3 sensörden birisi bulunmaktadır.

Uydunun temel özelliklerine ait bilgiler Tablo 4.1’de gösterilmiştir.

Tablo 4.1. PlanetScope uydu özellikleri

Özellik	Bilgi
Konumsal Çözünürlük	3 (yeniden örneklenmiş)
Radyometrik Çözünürlük	16 bit
Spektral Çözünürlük	Mavi: 455 - 515 nm Yeşil: 500 - 590 nm Kırmızı: 590 - 670 nm Yakın Kızıl Ötesi: 780 - 860 nm

Zamansal Çözünürlük	1 gün
Yörünge Yüksekliği	450 - 580 km
Yörünge Açısı	98 °
Çerçeve Genişliği	24 km x 8 km (Yaklaşık)-PS2 24 km x 16 km (Yaklaşık)-PS2.SD 32.5 km x 19.6 km (Yaklaşık) (PSB.SD)
Görüntü Çekme Kapasitesi	350M+ km ² /gün

Kullanıcılara sunulan PlanetScope görüntüleri farklı işleme seviyelerinde sunulmaktadır. Bu işleme seviyeleri Seviye 1B, Seviye 3B ve Seviye 3A'dır. Tablo 4.2'de bu ürünlerin özellikleri gösterilmiştir.


Tablo 4.2. PlanetScope uydu özellikleri

Ürün ismi	Tanımlama	Ürün seviyesi
-----------	-----------	---------------

PlanetScope Temel Ekran Ürünü	Ölçekli Atmosfer üstü parlaklığı (sensörde) veren ve sensörle düzeltilmiş üründür. Temek ekran ürünü, gelişmiş görüntü işleme ve geometrik düzeltme özelliklerine sahip kullanıcılar için tasarlanmıştır. Bu ürün ekran tabanlı çerçeveye sahiptir ve kartografik bir projeksiyona yansıtılmamıştır. Verilere radyometrik ve sensör düzeltmeleri uygulanır.	Seviye 1B
PlanetScope Orto-Ekran Ürün Ortorektifiye Edilmiş	Analitik ve görsel uygulamalar için uygun ölçeklendirilmiş Atmosfer Üstü Parlaklığı (sensörde) veya Yüzey Yansımasını veren görüntü ürünüdür. Bu ürün sahne tabanlı çerçeveye sahiptir ve kartografik bir projeksiyona yansıtılmıştır.	Seviye 3B
PlanetScope Orto-Parça Ürünü	Verilere radyometrik ve sensör düzeltmeleri uygulanmıştır. Görüntü ortorektifiye edilmiş ve bir UTM projeksiyonuna yansıtılmıştır.	Seviye 3A

5. YÖNTEM

Bu bölümde tez çalışması kapsamında uygulanan metodolojiye ait teorik anlatım gerçekleştirilecektir. Çalışmada uygulanan metodoloji Şekil 5.1’de gösterilmiştir.




Şekil 5.1. Tez çalışması kapsamında uygulanan metodolojiye ait şematik gösterim

Çalışma kapsamında öncelikli olarak, çalışma alanına ait PlanetScope görüntüleri indirilerek çalışma alanına göre düzenlenmiş ve Normalize Edilmiş Fark Bitki İndeksi (NDVI) analizine göre uygun asmaların çıkarılmasında kullanılacak görüntü seçimi gerçekleştirilmiştir.

Sınıflandırma işleminde gerekli eğitim verilerinin toplanması ve kullanılan algoritmaların doğruluk analizlerinin yapılması için Manisa Tarım İl Müdürlüğünden

Çiftçi Kayıt Sisteminde (ÇKS) kayıtlı parseller temin edilmiştir. Temin edilen parseller incelendiğinde alanda bulunan asmaları iyi temsil etmediği gözlemlenmiş ve bundan dolayı analiz işleminde kullanılan görüntüye yakın tarihli Google Earth Görüntüsü indirilerek yardımcı veri olarak kullanılmıştır. Gerekli ön veri toplama işlemleri gerçekleştirildikten sonra analiz işlemine geçilmiştir.

Analiz işleminde asmaların haritalanmasında piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma yaklaşımları kullanılmıştır (Şekil 5.2). Bu iki yaklaşım uzaktan algılamada yeryüzüne ait bilgi çıkarmada kullanılan en yaygın yaklaşımlardır. Aşağıdaki başlıklarda tez kapsamında uygulanan metodolojiye göre anlatımlar detaylandırılmıştır. Sınıflandırma algoritmaları ve doğruluk analizi her iki yöntemde de kullanıldığı için ayrı ayrı alt başlıklar halinde verilmiştir.



Şekil 5.2. Piksel tabanlı ve nesne tabanlı sınıflandırma

5.1. Piksel Tabanlı Sınıflandırma

Piksel tabanlı sınıflandırma işleminde sınıflandırma işlemi piksel seviyesinde gerçekleştirilmektedir. Bir görüntüyü içeren tüm pikseller kullanılan bir algoritma ile kendisine en yakın sınıfa atanmaya çalışılmaktadır. Piksel tabanlı sınıflandırmada

piksellerin sınıflandırılması için piksellerin sahip olduğu spektral değerlerden faydalanılmaktadır. Uydu görüntülerine piksel tabanlı sınıflandırma kontrolsüz sınıflandırma ve kontrolsüz sınıflandırma olmak üzere iki farklı şekilde uygulanmaktadır (Richards 2013).

5.1.1. Kontrolsüz Sınıflandırma

Kontrolsüz sınıflandırma, piksel tabanlı bir sınıflandırma biçimidir ve esasen bilgisayar tarafından otomatikleştirilmiş sınıflandırmadır. Kullanıcı, sınıfların sayısını belirler ve spektral sınıflar, yalnızca verilerdeki sayısal bilgilerine (yani, bantların veya indekslerin her biri için piksel değerlerine) dayalı olarak oluşturulur. Bu yaklaşımda kümeleme algoritmaları, verilerin doğal, istatistiksel gruplandırılmasını belirlemek için kullanılır. Pikseller, spektral benzerliklerine göre gruplandırılır. Kullanılan algoritma, verileri analiz etmek ve sınıflar halinde gruplandırmak için özellik uzayını kullanır. Özellik uzayı görüntüyü oluşturan bantların ikili kombinasyonlar şeklinde spektral değerlerine göre gösterildiği uzaydır (Richards 2013).

Kontrolsüz sınıflandırma işleminde en yaygın kullanılan yöntem “Tekrarlı Veri Analizi Yöntemi” ISODATA (Iterative Self Organizing Data Analyses Tecnique)’dir. Bu yöntem, tekrarlı olarak tüm sınıflandırmayı gerçekleştirme ve uygulanan her iterasyon sonrasında tekrardan istatistik hesaplaması yapmakta ve bu hesaplamalara göre görüntü pikselleri için uygun sınıf ataması yapmaktadır. Bu yöntem özellik uzayındaki piksellerin minimum uzaklığını karar kuralı olarak kullanır. Pikseller, analiz işlemine dahil edilen görüntünün sol üst köşesinden başlayarak, soldan-sağa ve satır-satır incelenerek uygun sınıf atanmaya çalışılır. Piksellerin her bir küme ortalaması ile arasındaki spektral uzaklık hesaplanır ve hesaplanan spektral uzaklık en çok hangi kümeye yakınsa piksel o sınıf kümesine atanır. Uygulamada ilk olarak kullanıcı tarafında belirlenen sınıf sayısı kadar oluşturulan kümenin ortalaması hesaplanır. İlk iterasyon işleminden sonra, her bir kümenin yeni ortalaması hesaplanarak, bu ortalamalar bir sonraki iterasyon kümelerinin belirlenmesinde girdi olarak kullanılır (Kim ve Liang 2016).

Kontrolsüz sınıflandırma görüntünün çekildiği alan tanımsız kaldığında başvuru alan yöntemidir. Bu yöntemde, arazi kullanım/arazi örtüsünün bilinmesine gerek yoktur.

Ancak görüntünün kümeleneceği sınıf sayısı kullanıcı tarafından belirlenir. Sınıflandırmada görüntü bantlarının spektral değerleri yardımı ile benzer piksellerin

otomatik olarak tespit edilmesi işlemi gerçekleşir. Tanımlanan bu piksel gruplarına sembol, değer veya etiketler atanır, gerektiğinde de benzer özellikteki sınıflar birleştirilir.

Kontrolsüz sınıflandırma sonucu üretilen sınıflar, spektral sınıflardır ve spektral sınıfların özellikleri başlangıçta bilinmemektedir. Kullanıcı sınıflandırılmış görüntüyü, spektral sınıfların değer bilgilerini tespit edebilmek için referans alacağı bir veri ile (harita, görüntü vs.) kıyaslama yapar. Buna göre kümelenen sınıfların arazideki gerçek isimlerini tanımlayabilir.

5.1.2. Kontrollü Sınıflandırma

Piksel tabanlı kontrollü sınıflandırma işlemi analiz işlemini gerçekleştiren kişi tarafında kontrolü sağlanan bir sınıflandırma yaklaşımıdır. Bu sınıflandırma yaklaşımında analist işlem yapacağı bölgeyi tanımaktadır. Kontrollü sınıflandırma işleminde öncelikle analist tarafından görüntüden çıkarılacak sınıfların neler olduğu belirlenir. Belirlen her bir sınıf için eğitim pikselleri toplanır. Toplanan pikseller kullanılarak öncelikle sınıflandırma modelinin oluşturulması için eğitim işlemi gerçekleştirilir. Yapılan eğitim işlemine göre görüntüdeki pikseller belirlenen sınıfa atanmaya çalışılır (Richards 2013).

Kontrollü sınıflandırmanın eğitim ve sınıflandırma aşamasında bir sınıflandırma algoritması kullanılır. Bu amaç için kullanılan birçok sınıflandırma algoritması bulunmaktadır. En çok kullanılan sınıflandırma algoritması En Çok Olabilirlik algoritmasıdır. Bunun yanında, En kısa uzaklık sınıflandırma yöntemi, Parallelepiped sınıflandırma yöntemi gibi algoritmalarda piksel tabanlı sınıflandırmada kullanılmaktadır. Son yıllarda ise destek vektör makineleri, karar ağaçları, rastgele orman gibi birçok makine öğrenme algoritmaları piksel tabanlı sınıflandırma işleminde kullanılmaktadır. Tez çalışması kapsamında kullanılan sınıflandırma algoritmaları 5.3 bölümünde anlatılmıştır (Al-Doski vd., 2013).

Tez çalışmasının piksel tabanlı sınıflandırma aşamasında kontrollü sınıflandırma yöntemi kullanılmıştır. Kontrollü sınıflandırma işleminde sınıflandırma yapılacak bölgenin doğru şekilde sınıflandırılması için belirlenen sınıflara ait eğitim verilerin doğru şekilde toplanması gerekmektedir. Bir sınıfa ait eğitim verisi toplanırken toplanan piksellerin sadece o sınıfa ait olmasına başka bir ifade ile sınıfları homojen olarak temsil eden piksellerin toplanmasına dikkat edilmelidir.

Eđitim verisi toplama ařasında seilen eđitim sahaları, belirli bir arazi rts tipini temsil ettiđi bilinen alanlardır. Bilgisayar, her eđitim alanındaki piksellerin spektral imzasını belirler ve bu bilgileri, her bir sınıfın ortalaması ve varyansı dahil olmak zere istatistikleri tanımlamak iin kullanır. Tercihen eđitim alanlarının konumu, sahadan toplanan verilere veya yksek znrlkl referans grntlere dayanmalıdır. Yazılımın grntnn geri kalanını dođru bir řekilde sınıflandırmasını sađlamak iin her sınıftaki tm deđiřkenliđi kapsayan eđitim verilerin toplamak nemlidir. Eđitim alanları, belirli bir arazi rts trnde bulunan deđiřkenlik aralıđını temsil etmiyorsa, sınıflandırma ok daha az dođru olabilir. Her sınıf iin ok ve kk eđitim alanları seilmelidir (Jensen 1996).

Kontroll sınıflandırmada zamanın ođu, gerek sınıflandırma srecinden nce eđitim ařamasında yapılır. Sınıflandırma alıřtırıldıđında ıktı, etiketlenmiř ve bilgi sınıflarına veya arazi rts trlerine karřılık gelen sınıflara sahip tematik bir grntdr. Kontroll sınıflandırma kontrolsz sınıflandırmadan ok daha dođru olabilir, ancak bu dođruluk byk lde; eđitim blgelerine, bireyin grnty iřleme becerisine ve sınıfların spektral farklılıđına bađlıdır. İki veya daha fazla sınıf, spektral yansımaları aısından birbirine ok benziyorsa (rneđin, im alanları ve yeni bymeye bařlamıř tarım alanları), sınıflandırmaların yanlıř olma eđilimi yksek olacaktır. Kontroll sınıflandırma, eđitim verilerinin dođru toplanmasını gerektirir. Eđitim verileri zayıf veya temsili deđilse, sınıflandırma sonuları da zayıf olacaktır. Bu nedenle kontroll sınıflandırma, denetimsiz sınıflandırmaya kıyasla genellikle daha fazla zaman ve maliyet gerektirir (Jensen 1996).

5.2. Nesne Tabanlı Sınıflandırma

Nesne tabanlı sınıflandırma iřleminde sınıflandırma sreci grnt nesnesi seviyesinde gerekleřmektedir. Nesne tabanlı sınıflandırma iin hem spektral hem de konumsal bilgiyi kullanır. Nesne tabanlı sınıflandırma yntemleri, geleneksel piksel tabanlı sınıflandırma tekniklerine kıyasla nispeten yakın zamanda geliřtirilmiřtir. Piksel tabanlı sınıflandırma, yalnızca her pikseldeki spektral bilgilere dayalıyken, nesne tabanlı sınıflandırma, nesneler veya grnt nesneleri olarak adlandırılan bir dizi benzer pikselden gelen bilgilere dayanır. Sınıflandırma ařamasında grnt nesnelerinin spektral zellikler, boyutu, řekli, dokusu ve ayrıca pikselleri evreleyen bir komřuluk iliřkisine

dayalı olarak sınıflandırma işlemi gerçekleştirilir. Nesne tabanlı sınıflandırma görüntü segmentasyonu ve sınıflandırma olmak üzere iki aşamalı bir süreçtir. Segmentasyon işleminde ilk önce seçilen bir segmentasyon algoritması ile görüntü bölütlemesi yapılır. Ardından her nesne sınıflandırılır. Bu tür sınıflandırma, görsel yorumlama sırasında insanlar tarafından yapılan analiz türünü taklit etmeye çalışır.

5.2.1. Görüntü Segmentasyonu

Görüntü segmentasyonu, nesne tabanlı sınıflandırmanın en önemli aşamasını oluşturmaktadır. Sınıflandırmanın başarısı yapılan segmentasyonun başarısına doğrudan bağlıdır. Segmentasyon, bir görüntüdeki piksellerin benzer spektral ve konumsal özelliklere sahip segmentler (nesneler) halinde gruplandırıldığı bir süreçtir. Bu nesnelerin veya özelliklerin her biri birden çok piksel içerir. Görüntüdeki bölümler ideal olarak, örneğin binalar veya ağaç taçları gibi gerçek dünya özelliklerine karşılık gelir. Segmentasyonda kullanılan çeşitli parametreler vardır.

Segmentasyon sürecinde segmentasyon algoritmaları kullanılmaktadır. Günümüzde nesne tabanlı sınıflandırma işleminde en çok kabul görmüş segmentasyon yöntemi çoklu çözünürlüklü segmentasyon yöntemidir (Happ vd., 2010). Çoklu çözünürlüklü segmentasyon yöntemi bir piksel seviyesinden başlayarak, nesnelerin konumsal ve spektral özelliklerine göre komşu nesnelerle birleşerek büyürler. Bu yöntemin temeli bölge geliştirme algoritmasına dayanmaktadır. Segmentasyon işleminde kullanıcı tarafından katman ağırlığı, ölçek, şekil ve bütünlük parametrelerinin tanımlanması gerekmektedir. Katman ağırlığı segmentasyona dahil edilen görüntü bantlarının önemini belirleyen bir özelliktir. Örneğin bir segmentasyonda NIR bandına 2 ağırlığı verilirse bu bant segmentasyon işleminde diğer bantlardan iki kat daha fazla etkili olur. Ölçek parametresi çoklu çözünürlüklü segmentasyon işleminin en önemli parametresidir. Bu parametre doğrudan oluşacak görüntü nesnelerinin büyüklüğünü etkiler. Eğer ölçek parametresi çok büyük bir değer olarak tanımlanırsa, sonuç görüntü nesneleri büyük nesneler şeklinde oluşur. Eğer çok küçük bir değer verilirse görüntü nesnelerin sayısı çok fazla ve boyutları çok küçük olur. Segmentasyon işleminde önemli olan optimum ölçek parametresinin tanımlanmasıdır. Bu optimum değer genellikle deneme yanılma yöntemi ile tekrarlı denemeler aracılığı ile belirlenir. Şekil parametresi görüntü segmentasyonu işleminde spektral değeri temsil eden renk değerinin mi yoksa

konumsal değeri temsil eden şekil değerinin mi etkili olacağını belirleyen bir parametredir. Bu parametre 0 ile 1 arasında değer alır. Eğer 1'e yakın bir değer verilirse segmentasyonda konumsal ya da şekilsel özellikler daha çok dikkate alınır. 0'a yakın bir değer verilirse segmentasyonda spektral değerler daha çok dikkate alınır. Bütünlük parametresi oluşan görüntü nesnesinin geometrik şekli ile ilgilidir. Bu değerde şekil parametresi gibi 0 ile 1 arasında bir değer alır. Eğer bu değer 1'e yakın bir değer olarak tanımlanırsa oluşan nesnelerin geometrisi dikdörtgene daha benzer yapıda oluşur (Belgiu ve Drăguț 2014; Happ vd. 2010).

5.2.2. Görüntü Metrikleri

Nesne tabanlı sınıflandırma işleminin sınıflandırma aşamasında farklı görüntü özelliklerinden yararlanılır. Bu görüntü metrikleri görüntünün spektral değerlerinden hesaplanan spektral metrikler, görüntü nesnelerinin şekilsel metrikleri, bantlardan hesaplanan dokusal özellikler olmak üzere üç başlık altında incelenebilir.

5.2.2.1. Spektral metrikler

Bir nesneye ait spektral metrikler, o görüntü nesnesini oluşturan piksellerin, bir katmandaki sahip olduğu değerler kullanılarak hesaplanır (Uça Avcı, 2017). Burada katman kavramı ile anlatılmak istenen, uydu görüntülerinin spektral bantları, bu bantlardan üretilmiş bant indisleri, yükseklik verisi, yükseklik verisinden üretilen eğim, bakı, eğrisellik vb. girdi verilerdir. Bir görüntü nesnesine ait hesaplanabilecek çok sayıda katman özelliği bulunmasına rağmen aşağıda en temel metrik değerleri verilmiştir

(Uça Avcı, 2017).

Ortalama değer: Nesneyi oluşturan piksellerin katman değerlerinin ortalaması olarak ifade edilir.

Standart sapma: Görüntü nesnesini oluşturan piksel katman değerleri dağılımı ile ilişkili olarak türetilen standart sapma değeridir.

Minimum ve maksimum: Görüntü nesnesini oluşturan piksellerin sahip olduğu minimum ve maksimum katman değeridir.

Dağılım: Genel anlamda görüntü nesnesinin istatistiksel sıklığını ifade eder. Örneğin, Segmentasyon işleminde aşırı bir ölçek değeri kullanıldığında genelleştirilmiş

görüntü nesneleri oluşacaktır. Bu durumda medyan değeri ortalamaya göre daha doğru sonuç verecektir. Çünkü genelleştirilmiş görüntü nesnesinde sınıflandırılmak istenen objeye ait olmayan piksellerde ortalama değerin hesaplanmasında dahil edilecektir. Bu durumda dağılım metriğinin kullanılması doğruluğu arttıracaktır.

Parlaklık: Görüntü nesnesini oluşturan piksellerinin spektral bantlardaki değerlerinin toplamının spektral bant sayısına bölünmesi ile elde edilen görüntü nesnesi metriğidir.

Maksimum fark: Değerlendirmeye alınan bantlar arasındaki farkı ifade eder. Görüntü ile ilişki: Her bir nesneye ait piksel değerlerinin ortalaması ile görüntüdeki tüm piksellerin ortalaması arasındaki farkı ifade eder.

Bant indisleri: Bant indisleri görüntü bantları arasındaki aritmetiksel işlemler sonucu elde edilen indisleri ifade etmektedir. Örneğin bitkilere yönelik yapılan uygulamalarda en yaygın kullanılan bant indisi normalize edilmiş fark bitki indisidir. Bu tez çalışması kapsamında eşitlik 5.1’de gösterilen NDVI indeksi hem uygun görüntü seçiminde hem de nesne tabanlı sınıflandırma işleminde kullanılmıştır.

$$NDVI = \frac{Yakın\ Kızıl\ Ötesi - Kırmızı}{Yakın\ Kızıl\ Ötesi + Kırmızı} \quad (5.1)$$

5.2.2.2. Şekilsel metrikler

Nesne tabanlı sınıflandırma yönteminde piksel tabanlı sınıflandırmadan farklı olarak oluşturulan nesnelerin şekilsel özellikleri kullanılabilir. Sınıflandırma işleminde yaygın kullanılan şekilsel metrikler aşağıda kısaca tanımlanmıştır (Uça Avcı, 2017).

Alan: Bir görüntü nesnesi içinde yer alan piksellerin toplam sayısı olarak ifade edilmektedir.

Uzunluk ve genişlik: Görüntü nesnesinin iskeletine bağlı olarak tanımlanan bir parametredir. Nesne iskeleti, görüntü nesnesinin içyapısını tanımlamada kullanılan bir unsurdur. Nesne iskeleti içerisindeki iskelet ana çizgisi, nesnenin uzunluğunu belirtir, genişlik ise iskelet ana çizgisinin kenar piksel uzunluklarının ortalamasının iki katı olarak hesaplanabilir.

Çevre: Görüntü nesnesi çevresindeki toplam piksel sayısını ifade eder.

Asimetri: Görüntü nesnesinin ana aksı boyunca simetrisinin hesaplanmasına bağlı olarak elde edilen parametre değeridir.

Yoğunluk: Görüntü nesnesinin uzunluk ve genişliğinin, nesneyi oluşturan piksel sayısına oranıdır.

Şekil indeksi: Görüntü nesnesinin çevre uzunluğunun, nesneyi oluşturan piksel sayısına oranıdır.

En/boy oranı: Görüntü nesnesinin genişlik ve uzunluğunun bir birine olan oranıdır.


5.2.2.3. Dokusal Metrikler

Görüntü dokusu, uzaktan algılanmış görüntülerin önemli bir bileşenidir. Doku, görüntüyü oluşturan piksellerin spektral parlaklık değerlerindeki değişkenliğin ve dizilişin ölçülmesi şeklinde tanımlanabilir. Doku, düzenli bir frekansta tekrar eden desen ve/veya desen kombinasyonu olarak da tanımlanmaktadır. Doku analizinde bir bölge içerisindeki dizilişin sayısal olarak hesaplanması için istatistiksel yaklaşımlar kullanılır (Haralick, 1979).

Doku analizinin yapılabilmesi için ilk önce görüntüden Eş Oluşum Matrisinin üretilmesi, daha sonra bu matris üzerinde istatistik bazı hesaplamaların yapılması gerekir. Haralick (1979) tarafından geliştirilen Gri Düzey Eş Oluşum Matrisleri (GLCM: Grey Level Cooccurrence Matrix), ikinci derece istatistikler olarak en yaygın kullanılan doku ölçütüdür. GLCM ölçütleri, piksel kombinasyonlarının meydana gelme sıklığının ölçüsünü tanımlamada kullanılan Eş Oluşum matrislerini baz alarak, insan beyni tarafından kolaylıkla algılanabilen doku özelliklerinin çıkartılmasında ve matematiksel olarak ölçülmesinde kullanılırlar (Haralick, 1979; Uça Avcı, 2017).

Bir Eş Oluşum matrisi, i parlaklık değerine sahip olan pikseller ile j parlaklık değerine sahip piksellerin belirli bir mesafe ve yönde kaç kez tekrarlandığı bilgisini içermektedir, diğer bir ifade ile birbiriyle komşu piksellerin ilişkisi, istatistiksel olarak tanımlanmaktadır (Uça Avcı, 2017).

Uygulamada referans pikseli belirlendikten sonra, hesaplamalarda hangi yöndeki komşu pikselin kullanılacağını da belirlenmesi gerekir. Bir başka deyişle GLCM doku ölçütleri, farklı açılarda uygulanabilmektedir (Şekil 5.3) (Uça Avcı, 2017).



Şekil 5.3. Doku hesaplamalarında kullanılan farklı açılar için piksel komşulukları (Uça Avcı, 2017)

Eş Oluşum Matrislerinden birçok doku bilgisi hesaplanabilir. Haralick (1973) tarafından 14 adet doku bilgisi bu matristen üretilmiştir. Zaman içerisinde farklı araştırmacılar tarafından geliştirilen hesaplamalarla bu sayı artmıştır. Ancak birçoğunun benzer nitelikte olduğu görülmektedir. Doku ölçütlerinin büyük bir kısmı GLCM'den doğrudan doğruya hesaplanabilirken, bazı doku ölçütleri (örneğin, GLDV: Gri Düzey Fark Vektörü (Gray-Level Difference Vector) ölçütleri), GLCM'den türetilen gri seviyesi fark vektöründen elde edilmektedir (Haralick, 1979). Şekil 5.4'de en yaygın kullanılan dokusal metrikler verilmiştir (Uça Avcı, 2017).

Doku ölçütü	Matematiksel Eşitlik
GLCM Homojenlik: Görüntü Nesnesinin Kendi içerisindeki homojenlik ölçüsüdür.	$\sum_{x,y=0}^{N-1} \frac{P_{x,y}}{1 + (x - y)^2}$
GLCM Kontrast: Homojenliğin tersi olarak tanımlanır. Görüntü nesnesi içerisindeki piksel değerlerinin birbirlerinden farklılık miktarının ölçüsüdür.	$\sum_{x,y=0}^{N-1} P_{x,y}(x - y)^2$
GLCM Farklılık: Kontrasta benzer, komşu pikseller arası farklılığın bir başka eşitlik ile ölçümüdür. Yüksek kontrastı olan yerlerde farklılık da yüksektir.	$\sum_{x,y=0}^{N-1} P_{x,y} x - y $
GLCM Entropi: GLCM doku değerlerinin dağılımı ile ilgili olup, entropinin yüksek olması eşit dağılımlı değerler, entropinin düşük olması 0 veya 1'e yakın dağılımlı değerler olduğunu gösterir.	$\sum_{x,y=0}^{N-1} P_{x,y}(-\ln P_{x,y})$
GLCM Açılal 2. Moment: Lokal homojenite ile ilgili bir doku ölçütüdür.	$\sum_{x,y=0}^{N-1} (P_{x,y})^2$
GLCM Ortalama Değer: Bir pikselin belli bir değere sahip bir pikselle birlikte bulunmasının (komşu olma sıklığı) ölçüsüdür.	$\mu_{x,y} = \frac{\sum_{x,y=0}^{N-1} P_{x,y}}{N^2}$
GLCM Varyans: GLCM değerlerinin ortalama değerden ne kadar farklı olduğunu ölçüsüdür.	$\sigma_{x,y}^2 = \sum_{x,y=0}^{N-1} P_{x,y}(x \cdot y - \mu_{x,y})$
GLCM Korelasyon: Karşılıklı ilişki olarak da adlandırılır. Komşu piksellerin, gri renk seviyesine olan lineer bağımlılığının ölçüsüdür.	$\sum_{x,y=0}^{N-1} P_{x,y} \left[\frac{(x - \mu_x)(y - \mu_y)}{\sqrt{(\sigma_x^2)(\sigma_y^2)}} \right]$

Şekil 5.4. En yaygın kullanılan dokusal metrikler x : satır sayısı; y : sütun sayısı; $P_{x,y}$: matrisin x,y koordinatlarında yer alan pikselin normalize değeri; N : satır veya sütun sayısı; μ : GLCM ortalama değeri; σ : GLCM standart sapması (Uça Avcı, 2017)

5.2.3. Sınıflandırma yöntemleri

Piksel tabanlı sınıflandırmada, her pikselin içerdiği spektral bilgi ayrı olarak değerlendirilirken, nesne tabanlı sınıflandırmada, görüntü nesnelere ait türetilen bütünleşik şekilsel, spektral, dokusal metrikler kullanılmaktadır. Böylelikle sınıflandırma işleminde daha fazla istatistiksel parametre kullanılmaktadır (Uça Avcı, 2017).

Nesneler genelde görüntünün karakteristik özelliklerine göre segmentasyon işlemi ile belirlenir ve daha sonra spesifik sınıflara atanır. Sınıf tanımları, bir veya birden fazla ölçüt için, o sınıfın alabileceği değer aralıkları belirlenerek yapılır. Tanımlanan nesne aralığı dışında kalan görüntü nesneleri, farklı bir sınıfa atanabilir ya da sınıflandırmadan çıkartılabilir (Uça Avcı, 2017).

Nesne tabanlı yaklaşımda, bir görüntü nesnesi yani bir piksel grubu ele alındığından, kullanılan ölçütler, bir piksel grubuna uygulanır. Diğer bir ifade ile bir görüntü nesnesi için, her ölçütün gerektirdiği hesaplamalar yapılarak, görüntü nesnesinin kullanılan tüm ölçütler için aldığı değerler elde edilir. Piksel tabanlı sınıflandırmada ağırlıklı olarak piksel yansıtım değerinin kullanıldığı dikkate alındığında, nesne tabanlı yaklaşımda çok sayıdaki ölçütün kriter olarak kullanılabilmesi, sınıflandırma doğruluğunu arttıran en güçlü etkidir (Uça Avcı, 2017).

Sınıf tanımlarında kullanılan ölçütler için belirlenen değer aralıkları, kontrollü veya kontrolsüz sınıflandırma (kural tabanlı sınıflandırma) olarak adlandırılan iki farklı yöntemle belirlenmektedir. Kullanılacak olan yöntemin seçiminde, sınıflandırmanın amacı, görüntü özellikleri, bölgeye ait yer gerçeği verilerinin varlığı ve kullanıcının tecrübesi göz önüne alınmalıdır (Uça Avcı, 2017).

5.2.3.1. Kontrollü sınıflandırma

Kontrollü sınıflandırma işleminde ilk adım olarak kullanıcı tarafından sınıflar belirlenir. Daha sonra her sınıf için, o sınıfı temsil eden eğitim nesneleri seçilir. Böylece her sınıf, kendini temsil eden eğitim nesnelerinin ölçüt değerleri baz alınarak belirlenen değer aralıkları ile tanımlanır (Uça Avcı, 2017). Sınıflandırma işleminde yaygın olarak rastgele orman, karar ağaçları, destek vektör makineleri, K- En yakın komşuluk, Naive Bayes gibi makine öğrenme algoritmaları kullanılmaktadır. Bu algoritmalar bölüm 5.3’de tanıtılmıştır.

5.2.3.2 kural tabanlı sınıflandırma

Kontrollü sınıflandırma işlemine benzer şekilde ilk adım olarak kullanıcı tarafından sınıflar belirlenir. Daha sonra her sınıf için o sınıfı en iyi temsil eden ölçütler ile kullanıcının o ölçütler için belirleyeceği değer aralıkları tanımlanır. Kullanıcı müdahalesi daha fazla olmasına rağmen, ölçütlerin değer aralıkları hiçbir eğitim sınıfı kullanılmadan belirlendiği için, bu yöntem kontrolsüz sınıflandırma kategorisinde yer almaktadır. ‘Üyelik Fonksiyonları’ yöntemi, kontrolsüz nesne tabanlı sınıflandırma yaklaşımına örnek verilebilir (Uça Avcı, 2017).

Üyelik fonksiyonları: Bu yöntemde her bir sınıf, karakteristik özellikleri ve özellik bilgilerinin dağılımıyla tanımlanır. Görüntü analizinde ilk olarak, her nesnenin tanımlanan özellikler için aldığı değerler hesaplanır (Nussbaum vd., 2006) ve bu

özellikler referans alınarak, nesnenin her bir sınıfa ait üyelik değeri bulunur. Bir başka deyişle sınıf tanımlarında kullanılan özellikler için eşik değerlerinin ya da dağılımlarının belirlenmesinin ardından, her nesnenin her bir sınıfa ait üyelik değerinin hesaplanması mümkün olmaktadır (Uça Avcı, 2017).

Her iki sınıflandırma yönteminde de yukarıda detaylı olarak tanımlanan metrikler ve/veya ölçüt değerleri mantık operatörleri ile birleştirilerek, birden fazla ölçüt ile sınıf tanımı yapılabilir. Eşik belirlemede operatör olarak, ‘büyüktür veya eşittir ($\geq$)’, ‘büyüktür ($>$)’, ‘eşittir ($=$)’, ‘küçüktür ($<$)’, ‘küçüktür veya eşittir ($\leq$)’ kullanılmaktadır. Birden fazla özellik ile tanımlanan sınıflar için yapılan tanımlamalar ise VE, VEYA vb. mantık operatörleri ile birleştirilir (Uça Avcı, 2017).

Bir sınıfı tanımlamak için kullanılan ölçüt için kriter, bir eşik değer ile verilebileceği gibi bir değer aralığı içerisinde tanımlı bir dağılım fonksiyonu ile de verilebilir. Her iki kriter, şematik olarak Şekil 3.6’da gösterilmektedir. Grafiklerde x eksenini o ölçüt için nesnenin alabileceği değerleri, y eksenini ise 0 ile 1 arasında değişen üyelik katsayısı değerini gösterir (Uça Avcı, 2017).

5.3. Sınıflandırma Algoritmaları

Bu tez çalışması kapsamında, En Çok Olabilirlik (EÇO), Rastgele Orman (RO), Destek Vektör Makineleri (DVM), K-En Yakın Komşuluk (K-EYK), Karar Ağaçları (KA) ve Naive Bayes (NB) algoritmaları kullanılmıştır. Aşağıda bu algoritmalarının tanımlamaları yapılmıştır.

5.3.1. En Çok Olabilirlik (EÇO) Algoritması

EÇO algoritması uzaktan algılamada piksel tabanlı kontrollü sınıflandırma işleminde uydu görüntülerinin sınıflandırılmasında sıklıkla tercih edilen bir algoritmadır. Bu algoritma, spektral farklılıkları kullanarak işlem yapar. Bu yöntem her pikselin bir sınıfa atanması mantığına dayanır. Sınıfların ilk olasılıkları hakkında bilgi mevcut olmadığı durumlarda tüm pikseller eşit olasılıklı olarak kabul edilir. Ayrıca; en çok benzerlik yöntemi, diğer sınıflandırma yöntemleri içerisinde en güvenilir olanıdır. Çünkü pikselleri hem parlaklık değerlerine göre hem de her sınıf için ayırım oluşturabilen varyans/kovaryans matris değerini baz alarak sınıflandırır. Bu yöntem normal dağılım gösteren veri setlerinde daha doğru sonuçlar vermektedir. Sınıflandırmanın temel eşitliği eşitlik 5.2’de gösterilmiştir.

$$D \propto \ln(a_c) \propto [0.5 \ln(|COV_c|)] \propto [0.5(X - M_c)^T (COV_c^{-1})(X - M_c)] \quad (5.2)$$

D: ağırlıklı uzaklık,

C: sınıf,

X: bir pikselin ölçü vektörü,

M_c : C sınıfına ait denetim alanının ortalama vektörü, a_c : Herhangi bir

pikselin C sınıfına ait olmasının % olasılığı, öncül olasılık,

COV_c : C sınıfına ait denetim alanı piksellerinin kovaryansı

$|COV_c|$: COV_c nin determinantı

5.3.2. K-En Yakın Komşuluk (K-EYK) Algoritması

K-EYK algoritması sınıflandırma ve regresyon analizlerinde kullanılan en basit makine öğrenme algoritmasıdır. Bu algoritma diğer kontrollü sınıflandırma algoritmalarının aksine, özel bir eğitim aşaması yoktur. Genel olarak tüm veri seti eğitim için kullanılır. K-EYK tembel bir makine öğrenme algoritması veya parametrik olmayan makine öğrenme algoritması olarak da tanımlanabilir. K-EYK ile sınıflandırma işlemi yapılırken aday noktaya en yakın diğer noktalar aranır. K, bilinmeyen noktanın en yakın komşularının sayısını ifade eder.

K-EYK sınıflandırmasında sonuç çıktı sınıf üyeliğidir. Bir aday nokta, kendisine komşu noktalarının çoğunluk oyuyla sınıflandırılır. Nokta en yakın kendisine yakın sınıf kümeleri arasından en yakın olanına atanır. Sınıflandırma işleminde seçilen noktanın hangi sınıfa atanacağını belirlemede seçili nokta ile diğer noktalar arasındaki mesafe hesaplanmaktadır. Öklid, Manhattan veya Hamming gibi yöntemlerden herhangi birinin yardımıyla test verileri ile eğitim verilerinin her satırı arasındaki mesafeyi hesaplanır. Mesafeyi hesaplamak için en yaygın kullanılan yöntem Öklid'dir.

5.3.3. Naive Bayes (NB) Algoritması

Naive Bayes algoritması, belirli bir veri kümesindeki değerlerin frekansını ve kombinasyonlarını sayarak bir olasılık kümesini hesaplayan basit bir makine öğrenme

sınıflandırıcısıdır. K-EYK gibi tembel bir öğrenme algoritmasıdır ve dengesiz veri kümelerinde de çalışabilmektedir. Algoritmanın temeli Bayes teoremini dayanmaktadır (ASPINALL 1992). Bayes teoreminde sınıf değişkeninin değeri dikkate alındığında tüm değişkenlerin bağımsız olduğu varsayılır. Bu koşullu bağımsızlık varsayımı, gerçek dünya uygulamalarında nadiren geçerlidir. Bundan dolayı algoritma Naive olarak karakterize edilir, ancak algoritma çeşitli kontrollü sınıflandırma problemlerinde hızlı bir şekilde öğrenme eğilimindedir. Algoritma sınıflandırma problemde bir eleman için tüm sınıflara ait olma olasılıkları hesaplanır. Hesaplanan olasılık değeri en yüksek olana göre sınıflandırma işlemi gerçekleştirilir. Az bir eğitim verisiyle çok başarılı işler çıkartabilir. Olasılık hesaplamasında kullanılan eşitlik 5.3’de gösterilmiştir (Saritas ve Yasar 2019).

$$P(A|B) = \frac{P(A) P(B|A)}{P(B)} \quad (5.3)$$

Burada;

$P(A|B)$, B olayı gerçekleştiğinde A olayının meydana gelme olasılığını

$P(A)$, A'nın meydana gelme olasılığını,

$P(B|A)$, A olayı meydana geldiğinde B olayının meydana gelme olasılığını,

$P(B)$, B olayının meydana gelme olasılığını göstermektedir.

5.3.4. Karar Ağacı (KA) Algoritması

Karar ağaçları, yorumlanmalarının kolay olması, veri tabanı sistemleri ile kolayca entegre edilebilmeleri, güvenilirliklerinin iyi olması nedenlerinden dolayı sınıflama modelleri içerisinde en yaygın kullanıma sahip olan yöntemlerdir. Bu yöntemler tahmin edici ve tanımlayıcı özelliklere sahiptir (Köktürk, 2012).

Karar ağacı düğüm, dal ve yaprak olarak adlandırılan üç temel kısımdan oluşan, anlaşılması oldukça kolay olan bir tekniktir. Bu ağaç yapısında her bir değişken bir düğüm tarafından temsil edilir. Dallar ve yapraklar ağaç yapısının diğer elemanlarıdır. Ağaçta en son kısım yaprak en üst kısım ise kök olarak adlandırılır. Kök ve yapraklar arasında kalan kısımlar ise dal olarak ifade edilir. Başka bir ifadeyle bir ağaç yapısı; verileri içeren bir kök düğümü, iç düğümler (dallar) ve uç düğümlerden (yapraklar) oluşur. Eğitim verilerine ait değişken bilgilerinden yararlanılarak bir karar ağacı yapısı oluşturulmasında temel


prensip verilere ilişkin bir dizi sorular sorulması ve elde edilen cevaplar doğrultusunda hareket edilerek en kısa sürede sonuca gidilmesi olarak ifade edilebilir. Bu şekilde karar ağacı sorulara aldığı cevapları toplayarak karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğümünde verilerin sınıflandırılması ve ağaç yapısının oluşturulması için sorular sorulmaya başlanır ve dalları olmayan düğümler ya da yapraklar bulunana kadar bu işlem devam eder (Köktürk, 2012).

Karar ağaçlarının oluşturulmasındaki en önemli adım ağaçtaki dallanmanın hangi kriterlere veya kıstasa göre yapılacağı ya da hangi değişken değerlerine göre ağaç yapısının oluşturulacağıdır. Literatürde bu problemin çözümü için geliştirilmiş çeşitli yaklaşımlar vardır. Bunlardan en önemlileri bilgi kazancı ve bilgi kazanç oranı, Gini indeksi, Twoing kuralı ve Ki-Kare olasılık tablo istatistiği yaklaşımlarıdır (Köktürk, 2012).

Karar ağacında bulunan her bir dalın belirli bir olasılığı mevcuttur. Bu sayede son dallardan köke veya istediğimiz yere ulaşana dek olasılıkları hesaplamamız mümkündür. Karar düğümü, gerçekleştirilecek testi belirtir. Bu testin sonucu ağacın veri kaybetmeden dallara ayrılmasına neden olur. Her düğümde test ve dallara ayrılma işlemleri ardışık olarak gerçekleşir ve bu ayrılma işlemi üst seviyedeki ayrımlara bağlıdır. Ağacın her bir dalı sınıflama işlemini tamamlamaya adaydır. Eğer bir dalın ucunda sınıflama işlemi gerçekleşmiyorsa, o dalın sonucunda bir karar düğümü oluşur. Ancak dalın sonunda belirli bir sınıf oluşuyorsa, o dalın sonunda yaprak vardır. Bu yaprak, veri üzerinde belirlenmek istenen sınıflardan biridir. Karar ağacı işlemi kök düğümünden başlar ve yukarıdan aşağıya doğru yaprağa ulaşana dek ardışık düğümleri takip ederek gerçekleşir (Köktürk, 2012).

Karar ağacı tekniğini kullanarak verinin sınıflanması iki basamaklı bir işlemdir. İlk basamak öğrenme basamağıdır. Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla sınıflama algoritması tarafından analiz edilir. Öğrenilen model, sınıflama kuralları veya karar ağacı olarak gösterilir. İkinci basamak ise sınıflama basamağıdır. Sınıflama basamağında test verisi, sınıflama kurallarının veya karar ağacının doğruluğunu belirlemek amacıyla kullanılır. Eğer doğruluk kabul edilebilir oranda ise kurallar yeni verilerin sınıflanması amacıyla kullanılır (Köktürk, 2012).

Karar ağaçları geçmiş veriye dayanarak yeni verilerin hangi sınıfa ait olduğuna, kurallar çıkartarak karar vermektedir. Karar ağacı, sorulan sorular ve alınan cevaplar doğrultusunda hareket eder ve sorulan sorulara alınan cevapları birleştirerek kurallar oluşturur. Oluşan ağaç birçok “eğer-ise”(if-then)’den oluşan kurallar bütünüdür de diyebiliriz. Soru sormaya verideki hangi değişkenden başlanacağına karar verildiğinde ilgili değişken ağacın kök düğümünü oluşturmuş olur. Kök düğümünden başlayarak, cevabı veritabanında bulunan sorular sorulup alınan cevaplara göre yeni düğümler oluşturulmaktadır. Her düğüm kendinden sonra iki dala veya ikiden fazla dala ayrılmaktadır. Oluşan düğümünden sonra yeni soru sorulamıyorsa dallanma bitmiştir ve bir sınıfı temsil eden yaprağa ulaşılmıştır. Şekil 5.5’de karar ağacını oluşturan kök düğüm, iç düğüm ve terminal düğümler gösterilmiştir (Köktürk, 2012).



Şekil 5.5. Karar ağacı örneği (Köktürk, 2012)

5.3.5. Rastgele Orman (RO) Algoritması

Rastgele Orman algoritması Breiman tarafından geliştirilmiş bir topluluk öğrenme algoritmasıdır. Rastgele orman, adından da anlaşılacağı gibi, bir topluluk olarak çalışan çok sayıda bireysel karar ağacından oluşur. Rastgele ormandaki her bir ağaç bir sınıf tahmini verir ve en çok oyu alan ağaç ilgili sınıfın tahminlenmesinde kullanılır (Breiman 2001).

Sınıflandırma yöntemleri, tek sınıflandırıcının yerine birden fazla sınıflandırıcının üretildiği ve sonrasında onların tahminlerinden yola çıkarak yeni verileri sınıflandıran öğrenme algoritmalarıdır. Rastgele Orman algoritması hem hızı hem de yüksek oranda doğru sonuçlar vermesi sebebi ile tercih edilen bir algoritma haline gelmiştir. RO

algoritması, fazla ağaç üretmek için tekrar tekrar bölünerek parçalanmış bir toplu öğrenme metodudur.

Algoritmanın ağaç geliştirme prensibi;

$$\sum_{k=1}^K h(x, \theta_k) \quad (5.4)$$

şeklindedir. Burada, x , girdi verisi iken, θ_k rastgele vektördür. Yeni bir objeyi sınıflandırmak için girdi verisi her bir ağaca yerleştirilir. Her ağaçtan elde edilen sınıflandırmalar oylanarak yüksek oya sahip sınıf seçilir.


İşlem sırasında iki adet değişkeni belirlemek önemlidir. Bunlar düğümde kullanılan değişkenlerin sayısı (m) ve geliştirilecek ağaçların sayısı (N)'dır. Bu değerler m girdi değişken sayısından (M) büyük olmayacak şekilde olmak kaydı ile deneme ve hata yöntemi kullanılarak belirlenir.

Algoritmada ağaç oluşturulurken budama yapılmaz. En yüksek sayıda ağaca erişmek için CART (Classification and Regression Tree) algoritmasını kullanmaktadır. Ayrıca bölünme işleminde en homojen sınıf dağılımına sahip düğümlere erişmek için Gini indeksi kullanmaktadır (Akar ve Güngör 2012).

5.3.6. Destek Vektör Makineleri (DVM) Algoritması

Makine öğrenme algoritmalarından birisi olan destek vektör makineleri, sınıflandırma, regresyon ve aykırı değerlerin tespiti için kullanılan bir dizi kontrollü öğrenme yöntemidir (Weston vd., 2000).

Basit bir doğrusal DVM sınıflandırıcı, iki sınıfı ayırmak için sınıflar arasında düz bir çizgi oluşturmayı hedefler. Bu, çizginin bir tarafındaki tüm veri noktalarının bir sınıfı temsil edeceği ve hattın diğer tarafındaki veri noktalarının farklı bir sınıfı göstereceği anlamına gelir. Bu, iki sınıf arasında geçirilebilecek sonsuz sayıda çizgi vardır. DVM algoritmasının amacı sınıfları optimum düzeyde ayıracak hiperdüzlemi oluşturmaktadır (Şekil 5.6) (Weston vd. 2000).



Şekil 5.6. DVM algoritması ile optimum hiperdüzlemin belirlenmesi

Destek Vektör makineleri ile ilgili önemli kavramlar aşağıdaki şekilde özetlenebilir.

Destek Vektörleri (Support Vectors): Hiper düzleme en yakın olan veri noktalarına destek vektörleri denir. Bu veri noktaları yardımıyla ayırma çizgisi tanımlanacaktır.

Hiperdüzlem (hyperplane): Şekil 5.6’da görüleceği gibi, farklı sınıflara sahip bir dizi nesne arasında bölünmüş bir karar düzlemi veya uzaydır.

Marj (Margin): Farklı sınıfların destek vektör veri noktalarındaki iki satır arasındaki boşluk olarak tanımlanabilir. Çizgiden destek vektörlerine olan dik mesafe olarak hesaplanabilir. Büyük marj iyi marj olarak kabul edilir ve küçük marj kötü marj olarak kabul edilir.

DVM ile sınıflandırmada kernel fonksiyonlarından faydalanılmaktadır. Sınıflandırma amaçlı olarak en yaygın kullanılan kernel fonksiyonları lineer, polinomal, radyal temelli fonksiyonlardır (Roli ve Fumera 2001).

5.4. Doğruluk Analizi

Uydu görüntüsü sınıflandırma işleminin doğruluk analizlerinde hata matrisleri yaygın olarak tercih edilen bir yaklaşımdır. Hata matrisinde sınıf sayılarına göre sütun ve satırlar oluşturulur. Matrisin köşegenleri arasında bulunan çapraz değerler doğru sınıflandırılmış değerleri dışında kalan değerler yanlış sınıflandırılmış değerleri ifade eder. Hata matrisinde dört farklı doğruluk değeri hesaplanabilir. Bunlar; üretici doğruluğu (Ü.D), kullanıcı doğruluğu (K.D), genel doğruluk (G.D) ve Kappa (K) değerleridir

(Dizdaroğlu, 2019). Bu doğruluk ölçütlerine ait eşitlikler aşağıda sırası (Eşitlik 5.3-Eşitlik 5.6) ile verilmiştir.

$$\ddot{D}_{jj} = \frac{n_{jj}}{n_{+j}} \quad (5.3)$$

j: hata matrisindeki sütunlar n_{jj} : j. sütun ve j. satırındaki gözlemlerin sayısı (matris köşegeni üzerinde) n_{+j} : j. sütundaki gözlemlerin toplamı

$$K.D_i = \frac{n_{ii}}{n_{i+}} \quad (5.4)$$

i: hata matrisindeki satırlar n_{ii} : i. satır ve i. sütunundaki gözlemlerin sayısı (matris köşegeni üzerinde) n_{i+} : i. satırındaki gözlemlerin toplamı

$$G.D = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (5.5)$$

n: satır veya sütunların toplamı k:

hata matrisindeki sütun sayısı

$$Kappa(\hat{K}) = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} X x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} X x_{+i})} \quad (5.6)$$

r = hata matrisindeki satır sayısı

X_{ii} = i satırındaki ve i sütunundaki gözlem sayısı (ana köşegende)

(X_{i+}) = i satırındaki gözlemlerin toplamı

(X_{+i}) = i sütunundaki gözlemlerin toplamı

N = matrise dâhil edilen toplam gözlem sayısını ifade eder.


6. ANALİZ VE BULGULAR

Bu tez çalışması kapsamında PlanetScope görüntülerinden asmaların farklı sınıflandırma yaklaşımları ve farklı sınıflandırma algoritmaları ile haritalanması işlemi gerçekleştirilmiştir. Çalışmada öncelikle analiz işleminde kullanılacak görüntü seçimi gerçekleştirilmiş ardından sınıflandırma uygulamaları yapılmıştır. Araştırma kapsamında yapılan işlemler aşağıda alt başlıklar olarak verilmiştir.

6.1. Verilerin Hazırlanması

Veri hazırlama sürecinde analiz işleminde kullanılacak yardımcı verilerin temini ve uygun görüntü seçimi işlemi gerçekleştirilmiştir. Çalışma kapsamında asmaların haritalanması için 2019 yılı seçilmiştir. 2019 yılına ait Çiftçi Kayıt Sisteminde bulunan tarım parselleri ve bu parsellerde ekili olan ürünler Manisa İl Tarım Müdürlüğünden temin edilmiştir. ÇKS verilerinde bulunan asma alanları incelendiğinde çalışma sahasındaki bazı parsellerin bu veri içinde olmadığı, bazı parsellerde asma yetiştirildiği yazdığı ancak uydu görüntüsünde ilgili alanın boş alan olduğu görülmüştür (Şekil 6.1). Bundan dolayı sınıflandırma aşamasında yardımcı olması açısından Google Earth Pro yazılımından analiz tarihine yakın tarihli yüksek konumsal çözünürlük görüntü indirilmiştir. Bu veri koordinatlı olarak indirilerek kullanılmıştır. ÇKS ve Google Earth verileri eğitim verisi toplama ve doğruluk analizi işlemlerinde yardımcı veri olarak kullanılmıştır.

Çalışma alanına ait ÇKS verilerindeki ürünler ve Google Earth görüntüleri incelendiğinde alanda asma alanları dışında aynı dönemde birçok parselde mısır ve pamuk ekili olduğu görülmüştür. Bu ürünlerin dışında alanda zeytin bahçelerinin olduğu görülmektedir. Ayrıca alandaki parsellerinden bazıları nadas alanı olduğu görülmüştür. Analize tabi tutulacak alanda tarımsal kullanımın yanında yapay yüzeyler olarak binalı bölgeler, yollar ve boş alanlar bulunmaktadır.



Şekil 6.1. Google Earth görüntüsü ve ÇKS asma parselleri

Analiz işleminde kullanılacak uygun PlanetScope görüntüsünün belirlenmesi için <https://www.planet.com/explorer/> web sitesinden çalışma alanı sınırlarına göre asmanın gelişme tarihlerine göre mayıs ayından eylül ayına kadar olan görüntüler indirilmiştir. Çalışma sahasının üzerinden geçen PlanetScope (PS) uydular farklı boyutlarda görüntüler çekmektedir. Bundan dolayı çalışma sahası birden çok görüntüden oluşabilmektedir. Seçilen görüntüler alanı 2 çerçevede kaplamaktadır. İndirilen görüntüler PS uydularının dört bandını içeren 3 m mekânsal çözünürlükteki görüntülerdir. Bunlar öncelikle


mozaiklenmiş ardından çalışma alanına göre kesilmiştir. İndirilen görüntüler atmosfer altı yüzey yansımalarını veren ve analitik işlemlerde kullanılabilen görüntülerdir.

Analizde uygun tarihli görüntünün seçilmesi için indirilen her bir görüntüden NDVI haritası üretilmiştir. ÇKS verileri ve Google Earth görüntülerinden yararlanarak asma parsellerinin iç bölgelerinde poligonlar çizilmiştir. Bu poligonların ortalama NDVI değerleri hesaplanmıştır. Çalışma kapsamında toplam 60 parselden NDVI değeri alınmıştır. Kullanılan her bir görüntüden çizilen poligonlara göre üretilen ortalama NDVI değerleri Tablo 6.1’de ve tarihlere göre üretilen NDVI grafiği Şekil 6.2’de gösterilmiştir.

Tablo 6.1 ve Şekil 6.2 incelendiğinde asma parsellerindeki NDVI değeri Mayıs ayından itibaren artışa geçerek 12.07.2019 tarihinde maksimum seviyeye ulaşmıştır. Bu tarihten sonra düşüşe geçmiştir.

Tablo 6.1. PlanetScope Görüntü tarihlerine göre asma parsellerinin ortalama NDVI değerleri


Tarih	NDVI
16.05.2019	0.32
01.06.2019	0.53
14.06.2016	0.59
28.06.2019	0.63
12.07.2019	0.67
13.07.2019	0.60
22.07.2019	0.65
25.07.2019	0.59
05.08.2019	0.60
23.08.2019	0.53



Şekil 6.2. Çalışma alanına ait farklı tarihli PlanetScope görüntülerindeki NDVI değişimi

Çalışma kapsamında indirilen görüntülerden en uygun tarihli görüntü 12.07.2019 tarihli görüntü olduğu görülmüştür. Ancak, bu görüntüde çalışma alanının batı bölümünde büyük bir alan eksik olduğu için kullanılamamıştır. Bu görüntüye en yakın tarihli olan 13.07.2019 tarihli görüntüde de radyometrik bozulmalar tespit edilmiştir. Bundan dolayı çalışma kapsamında analiz işleminde 22.07.2019 tarihli görüntü tercih edilmiştir.

Uygun tarihli görüntünün belirlenmesinden sonra çalışma sahası eğitim verisi alanı ve test alanı olmak üzere ikiye bölünmüştür (Şekil 6.3). Eğitim verisi alanında sınıflandırma işleminde kullanılacak eğitim verileri toplanmış bu eğitim verilerine göre her bir algoritma için model eğitilmiş ve test alanı sınıflandırılmıştır.




Şekil 6.3. Çalışma alanına ait eğitim ve test sahaları

6.2. Asmaların Piksel Tabanlı Haritalanması


Tez çalışması kapsamında öncelikle piksel tabanlı sınıflandırma işlemi gerçekleştirilmiştir. Piksel tabanlı sınıflandırma ArcGIS 10.8 yazılımında görüntü sınıflandırma fonksiyonları kullanılarak yapılmıştır. Sınıflandırma işlemi için çalışma alanına asma, diğer tarım alanları, yapay yüzeyler, nadas-toprak yol olmak üzere dört sınıf tanımlaması yapılmıştır. Tanımlanan her bir sınıf için ÇKS verilerinden ve Google Earth görüntüsü yardımı ile eğitim verileri toplanmıştır. Eğitim verisi toplanırken her sınıfı temsil eden homojen pikseller toplanmaya özen gösterilmiştir. Şekil 6.4’de piksel tabanlı sınıflandırma için toplanan örnek eğitim verileri sunulmuştur.

Piksel tabanlı sınıflandırma için EÇO, DVM ve RO sınıflandırma algoritmaları kullanılmıştır. Sınıflandırma işleminde girdi olarak PlanetScope görüntüsünün mavi, yeşil, kırmızı ve yakın kızıl ötesi bantları kullanılmıştır. Ayrıca, tüm sınıflandırma algoritmaları aynı eğitim verisi ile eğitilerek test alanına uygulanmıştır.



Şekil 6.4. Piksel tabanlı sınıflandırma için toplanan eğitim verileri

Çalışma kapsamında kullanılan algoritmaların doğruluklarını test etmek için test alanı olarak seçilen alana rastgele 300 adet nokta atılmıştır. Atılan bu noktaların yer doğrulama değerleri ÇKS verileri ve Google Earth görüntüsünden destek alınarak veritabanına girilmiştir. Ardından her bir algoritma için ayrı ayrı doğruluk analizi işlemi gerçekleştirilmiştir. Doğruluk analizi için rastgele üretilen noktalar Şekil 6.5’de gösterilmiştir.




Şekil 6.5. Algoritmaların doğruluk analizi işleminde kullanılan noktaların konumsal dağılımı

Tez kapsamında ilk önce EÇO algoritması ile sınıflandırma işlemi gerçekleştirilmiştir. Bu algoritma ile sınıflandırma yapılırken, öncelikle eğitim alanlarına göre model eğitilmiş, oluşturulan EÇO sınıflandırıcı ile test alanı sınıflandırılmıştır.

Elde edilen sonuç harita Şekil 6.6'da verilmiştir. Sınıflandırma sonucuna ait doğruluk değerleri ise Tablo 6.2'de gösterilmiştir. Tablo 6.2 incelendiğinde, EÇO algoritması ile asma alanlarına ait kullanıcı doğruluğu %84, üretici doğruluğu %85 olarak elde edilmiştir. Sınıflandırma sonucu üretilen diğer alanlar incelendiğinde, pamuk, mısır ve diğer tarımsal ürünleri içeren diğer tarım alanı sınıfı en yüksek doğrulukla sınıflandırılmıştır. Bu sınıf üretici doğruluğu %91, kullanıcı doğruluğu %92 olarak elde

edilmiştir. Diğer tarım alanları sınıfı gibi EÇO algoritması ile Nadas-Toprak yol sınıfında da yüksek doğruluk değerleri elde edildiği görülmektedir. En düşük doğruluk değeri kullanıcı doğruluğu olarak %67'lik oranla yapay yüzeylerde elde edilmiştir. EÇO algoritmasının tüm sınıflardaki başarı oranı incelendiğinde, algoritma üretilen haritanın genel doğruluğu %88 ve Kappa değeri 0.82 olarak elde edilmiştir.



Şekil 6.6. *Piksel tabanlı EÇO algoritması ile üretilen sınıflandırma haritası*


Tablo 6.2. *Piksel Tabanlı EÇO algoritması ile elde edilen doğruluk değerleri*

Sınıflar	Asma	Diğer Tarım Alanları	NadasYol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
----------	------	----------------------	----------	----------------	--------	---------------------

Asma	81	11	4	0	96	0.84
Diğer Tarım Alanları	9	113	1	0	123	0.92
Nadas-Yol	5	0	60	1	66	0.91
Yapay Yüzeyler	0	0	5	10	15	0.67
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.85	0.91	0.86	0.91		
Genel Doğruluk: 0.88				Kappa: 0.82		

Piksel tabanlı asmaların haritalanmasında ikinci olarak RO algoritması uygulanmıştır. RO algoritmasında sınıflandırma işlemi için algoritmanın oluşturması gereken ağaç sayısı ve minimum değişken sayısının belirlenmesi gerekmektedir. ArcMap 10.8 yazılı RO algoritması için sadece ağaç sayısının belirlenmesine imkan vermektedir. Bundan dolayı piksel tabanlı sınıflandırma işleminde sadece uygun ağaç sayısı belirlenmiştir. Yapılan denemeler sonucunda veri seti için en uygun ağaç sayısı 300 olarak belirlenmiş ve sonuç sınıflandırma işlemi buna göre gerçekleştirilmiştir.

RO algoritması ile üretilen piksel tabanlı sınıflandırma haritası Şekil 6.7’de, bu haritaya ait doğruluk değerleri Tablo 6.3’de gösterilmiştir. Tablo 6.3 irdelendiğinde, RO algoritması ile asmaların haritalanmasında hem üretici hem de kullanıcı doğruluklarında %85 başarı elde edilmiştir. Diğer tarım alanlarının da %90 üzerinde başarı ile haritalandığı görülmektedir. Nadas – toprak yol alanların haritalanmasında kullanıcı doğruluğu %90, üretici doğruluğu %86 olarak elde edilmiştir. Yapay yüzeyler de ise bu oranları kullanıcı doğruluğu %77, üretici doğruluğu %91 olarak elde edilmiştir.




Şekil 6.7. Piksel tabanlı RO algoritması ile üretilen sınıflandırma haritası

Tablo 6.3. Piksel Tabanlı RO algoritması ile elde edilen doğruluk değerleri

Sınıflar	Asma	Diğer Tarım Alanları	NadasYol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	81	9	5	0	95	0.85
Diğer Tarım Alanları	9	114	2	0	125	0.91
Nadas-Yol	5	1	60	1	67	0.90
Yapay Yüzeyler	0	0	3	10	13	0.77
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.85	0.92	0.86	0.91		0.88
Genel Doğruluk: 0.88					Kappa: 0.83	

Asma alanlarının piksel tabanlı olarak haritalanmasında uygulana son algoritma DVM algoritmasıdır. Algoritma ile üretilen sonuç harita Şekil. 6.8’de gösterilmiştir. Algoritmaya ait doğruluk değerleri tablo 6.4’de verilmiştir. Elde edilen sonuçlar incelendiğinde, DVM algoritması ile asma alanlarının doğruluk değerleri kullanıcı doğruluğu %81, üretici doğruluğu %85 olarak elde edilmiştir. Diğer tarım alanlarının haritalanmasında kullanıcı doğruluğu %90, üretici doğruluğu %92 olarak hesaplanmıştır. Nadas ve toprak yollar her iki doğruluk ölçütünde %85’in üzerinde bir başarı ile haritalanmıştır. Yapay yüzeylerde ise %77 üzerinde başarı sağlanmıştır. DVM algoritması ile üretilen haritanın genel doğruluğu %87, Kappa değeri 0.81 olarak hesaplanmıştır.



Şekil 6.8. Piksel tabanlı DVM algoritması ile üretilen sınıflandırma haritası

Tablo 6.4. *Piksel Tabanlı DVM algoritması ile elde edilen doğruluk değerleri*

Sınıflar	Asma	Diğer Tarım Alanları	NadasYol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	81	10	9	0	100	0.81
Diğer Tarım Alanları	10	114	2	0	126	0.90
Nadas-Yol	4	0	57	1	62	0.92
Yapay Yüzeyler	0	0	2	10	12	0.83
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.85	0.92	0.81	0.91		0.87
Genel Doğruluk: 0.87					Kappa: 0.81	


6.3. Asmaların Nesne Tabanlı Haritalanması

Çalışma kapsamında uygulanan nesne tabanlı sınıflandırma işlemi, Ecognition Developer 9.0 yazılımında gerçekleştirilmiştir. Nesne Tabanlı sınıflandırma işleminin ilk adımını görüntü segmentasyonu oluşturmaktadır. Görüntü segmentasyonunda amaç sınıflandırmada kullanılacak uygun görüntü nesnelerinin üretilmesidir. Çalışma kapsamında PlanetScope uydu görüntülerinden görüntü nesnelerinin üretilmesi için çoklu çözünürlüklü segmentasyon yöntemi kullanılmıştır. Bu segmentasyon işleminde, çalışma alanına uygun görüntü nesnelerinin üretilmesi için katman ağırlığı, ölçek, şekil ve bütünlük parametrelerinin kullanıcı tarafından belirlenmesi gerekmektedir.

Segmentasyon işleminde PlanetScope görüntülerinin mavi, yeşil, kırmızı ve yakın kızılötesi bantların hepsi girdi katman olarak belirlenmiştir. Yapılan denemeler sonucunda çalışma sahası için katman ağırlıkları tüm bantlara bir olarak atanmıştır. Segmentasyon işleminde, uygun ölçek parametresini belirlemek için 10'dan 100'e kadar farklı değerler denenmiştir. Yapılan denemeler sonucunda çalışma alanı için uygun ölçek parametresi 50 olarak tespit edilmiştir. Belirlenen ölçek parametresi için uygun şekil değeri 0.1, bütünlük değeri ise 0.9 olarak belirlenmiştir. Bu değerlere göre sınıflandırma işleminde kullanılacak görüntü nesneleri üretilmiştir. Şekil 6.9'da alana ait örnek segmentasyon görseli sunulmuştur.

Segmentasyon işleminde genellikle çıkarılmak istenilen detay tek bir görüntü nesnesinde olması istenir. Ancak bazı durumlarda bir obje birden çok görüntü

nesnesinden oluşabilir. Tez çalışmasında yapılan segmentasyon işleminde belirlenen 50 ölçek değeri için asma parselleri birden çok görüntü nesnesinden oluşmaktadır. Bunun en temel nedeni, ölçek parametresi değeri 50'nin üzerinde bir değer verdiğinde asma parselleri ile diğer arazi kullanım sınıfları bir birine karışmaktadır. Bundan dolayı çalışmada 50 ölçek değeri tercih edilmiştir.




Şekil 6.9. *Piksel tabanlı RO algoritması ile üretilen sınıflandırma haritası*

Segmentasyon işleminden sonra eğitim verisi toplama aşamasına geçilmiştir. Piksel tabanlı sınıflandırma da olduğu gibi, asma, diğer tarım alanları, nadas-toprak yol ve yapay yüzeyler olmak üzere 4 sınıf oluşturulmuştur. Bu sınıflara ait eğitim verileri mümkün olduğunca piksel tabanlı sınıflandırma işleminde belirlenen alanlar üzerinden toplanmıştır.

Nesne tabanlı sınıflandırma işleminde, piksel tabanlı sınıflandırmadan farklı olarak spektral değerlerin yanında, geometrik ve dokusal değerler de sınıflandırma işleminde kullanılabilir. Çalışma kapsamında kullanılan yazılımı, gerek geometrik gerekse dokusal olarak birçok parametre üretebilmektedir. Bu parametrelerin hepsini sınıflandırma işleminde kullanmak veri işleme hızını düşürmekte ve bazı durumlarda istenmeyen sonuçlar ortaya çıkarabilmektedir. Bundan dolayı nesne tabanlı

sınıflandırmada eğitim verisi toplama aşamasından sonra özellik seçimi işlemi sınıflandırmada kullanılacak özelliklerin seçilmesi veri boyutunun düşürülmesi açısından önemlidir.

Bu çalışma kapsamında, görsel analizlerle spektral, geometrik ve dokusal 26 adet görüntü metriği (özellik) belirlenmiştir. Sınıflandırma işlemine geçmeden önce bu metrikleri azaltmak için Ecognition yazılımın özellik seçim fonksiyonu ile en önemli özellikler belirlenmiştir. Ecognition yazılımı toplanan eğitim verileri ve belirlenen özellikler arasından sınıflandırma işleminde kullanılacak özelliklerinin optimizasyonunu yapma yeteneğine sahiptir. Belirlenen 26 özelliğin optimizasyonunda yazılım aracılığı ile 18 özelliğin uygun olacağı belirlenmiştir. Şekil 6.10'da optimum 18 özellik dışında diğer özelliklerin sınıflandırmaya etkisi olmadığı görülmektedir.



Şekil 6.10. Özellik uzayı optimizasyonu sonucu

Yapılan özellik seçimi ile belirlenen 18 parametre Tablo 6.6’da gösterilmiştir. Bu tabloya göre sınıflandırma işleminde 6 spektral görüntü metriği, 6 geometrik görüntü metriği ve 6 adet dokusal görüntü metriği kullanılmıştır.


Tablo 6.5. Nesne tabanlı sınıflandırma işleminde kullanılan görüntü metrikleri (özellikler)

Özellik Türü	Özellik adı
Spektral	• NDVI • Maksimum Fark • Mavi bant standart sapma • Yeşil bant standart sapma • Kırmızı bant standart sapma • Yakın kızıl ötesi bant standart sapma
Geometrik	• Genişlik • En/boy oranı • Dikdörtgene benzerlik • Asimetri • Bütünlük • Yoğunluk
Dokusal	• GLCM yakın kızıl ötesi bant benzeşmezlik • GLCM yakın kızıl ötesi bant kontrast • GLCM yakın kızıl ötesi bant korelasyon • GLCM yakın kızıl ötesi bant entropi • GLCM yakın kızıl ötesi bant standart sapma • GLCM yakın kızıl ötesi bant ortalama

Çalışma kapsamında öncelikle K-EYK algoritması kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. K-EYK algoritması ile sınıflandırma işleminde K değerine 1, 2, 3 değerleri verilerek sınıflandırma işlemi gerçekleştirilmiş. Yapılan görsel analizlerde en iyi sonucun K=1 değeri ile elde edildiği görülmüştür. Bu değer kullanılarak nihai sınıflandırma işlemi gerçekleştirilmiştir. Yapılan sınıflandırma işleminin doğruluğu piksel tabanlı sınıflandırma işleminde kullanılan 300 nokta ile gerçekleştirilmiştir.

K-EYK algoritması ile yapılan sınıflandırma işlemi sonucu Şekil 6.11’de, haritaya ait doğruluk değerleri Tablo 6.6’da gösterilmiştir. Tablo incelendiğinde, K-EYK algoritması asma alanlarını hem kullanıcı hem de üretici doğruluğuna göre %85 başarı ile sınıflandırmıştır. Asma alanı dışında kalan diğer tarım alanlarında %90 üzerinde üretici ve kullanıcı doğruluğu elde edilmiştir. Nadas ve Toprak yol sınıfının üretici doğruluğu, %86, kullanıcı doğruluğu %90 olarak hesaplanmıştır. Yapay yüzeylerde ise kullanıcı doğruluğunda %77, üretici doğruluğunda %91’lik başarı elde edilmiştir. Algoritmanın genel sınıflandırma performansı incelendiğinde, genel doğruluğun %88, Kappa değerinin

0.83 olduğu görülmüştür.



Şekil 6.11. Nesne tabanlı K-EYK algoritması ile üretilen sınıflandırma haritası

Tablo 6.6. Nesne Tabanlı K-EYK algoritması ile elde edilen doğruluk değerleri

Sınıflar	Asma	Diğer Tarım Alanları	Nadas -Yol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	81	9	5	0	95	0.85
Diğer Tarım Alanları	9	114	2	0	125	0.91
Nadas-Yol	5	1	60	1	67	0.90
Yapay Yüzeyler	0	0	3	10	13	0.77
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.85	0.92	0.86	0.91		

Genel Doğruluk: 0.88


Kappa: 0.83

Nesne tabanlı asmaların haritalanmasında ikinci olarak NB algoritması kullanılmıştır. NB algoritması ile sınıflandırma işlemi yapılırken yazılımda herhangi bir parametrenin belirlenmesi gerekmemektedir. Bundan dolayı toplana eğitim verilerine göre model eğitilmiş ve ardından test alanı sınıflandırılmıştır.

NB algoritmasına göre test alanın sınıflandırılmış haritası Şekil 6.12’de gösterilmiştir. Algoritma ile yapılan haritalamaya ait doğruluk değerleri Tablo 6.7’de verilmiştir. Tablo incelendiğinde, NB algoritmasının asma alanlarını haritalamadaki kullanıcı doğruluğu %91, üretici doğruluğu %75 olarak elde edilmiştir. Diğer tarım alanlarını haritalamada kullanıcı doğruluğu, %80, üretici doğruluğu %75 olarak hesaplanmıştır. Nadas ve toprak yol alanlarında kullanıcı doğruluğunun %92, üretici doğruluğunun %69 olduğu görülmektedir. Algoritmanın yapay yüzeyleri çıkarma başarısı kullanıcı doğruluğunda %55, üretici doğruluğunda %100’dür. Algoritmanın genel performansı, genel doğruluk %83, Kappa değeri 0.75’dir.

Tablo 6.7. Nesne Tabanlı NB algoritması ile elde edilen doğruluk değerleri

Sınıflar	Asma	Diğer Tarım Alanları	NadasYol	Yapay yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	71	4	3	0	78	0.91
Diğer Tarım Alanları	19	120	11	0	150	0.80
Nadas-Yol	4	0	48	0	52	0.92
Yapay yüzeyler	1	0	8	11	20	0.55
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.75	0.97	0.69	1.00		
Genel Doğruluk: 0.83					Kappa: 0.75	




Şekil 6.12. Nesne tabanlı NB algoritması ile üretilen sınıflandırma haritası

Çalışma kapsamında nesne tabanlı sınıflandırma yaklaşımında üçüncü olarak uygulanan algoritma Karar Ağacı algoritmasıdır. KA algoritması ile yapılan sınıflandırma işleminde yapılan denemeler sonucunda maksimum kategori sayısı 16 ve çapraz doğrulama sayısı 3 olarak tespit edilip sınıflandırma işlemi gerçekleştirilmiştir. Yapılan sınıflandırma işlemine ait sonuç harita Şekil 6.13’de, üretilen haritanın doğruluk değerleri ise Tablo 6.8’de gösterilmiştir. KA algoritmasının asmaların tespitindeki başarısı üretici doğruluğunda, %80, kullanıcı doğruluğunda %85 olarak elde edilmiştir. Diğer tarım alanları %90 üzerinde başarı ile haritalanmıştır. Nadas ve toprak yol alanlarında %85 üzerinde bir başarı sağlanmıştır. Algoritma ile üretilen haritanın genel doğruluğu %88, Kappa değeri 0.82 olarak elde edilmiştir.

Tablo 6.8. Nesne Tabanlı KA algoritması ile elde edilen doğruluk değerleri

Sınıflar	Asma	Diğer Tarım Alanları	NadasYol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	76	7	6	0	89	0.85
Diğer Tarım Alanları	10	116	1	0	127	0.91
Nadas-Yol	9	1	60	0	70	0.86
Yapay Yüzeyler	0	0	3	11	14	0.79
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.80	0.94	0.86	1.00		
Genel Doğruluk:0.88					Kappa: 0.82	




Şekil 6.13. Nesne tabanlı KA algoritması ile üretilen sınıflandırma haritası

Nesne tabanlı asmaların haritalanmasında dördüncü olarak RO algoritması uygulanmıştır. RO algoritması uygulanırken, oluşturulacak rastgele ağaç sayısı ve seçilecek minimum değişken sayısı kullanıcı tarafından seçilmektedir. Bu değerler deneme yanılma yolu ile çalışma sahası için ağaç sayısı 500 minimum değişken sayısı 5 olarak belirlenmiş ve sınıflandırma işlemi buna göre gerçekleştirilmiştir. Üretilen sonuç harita Şekil 6.14’de, haritaya ait doğruluk değerleri Tablo 6.9’da verilmiştir. Elde edilen sonuçlar incelendiğinde RO algoritmasının asma alanlarını haritalamadaki başarısı kullanıcı doğruluğunda %88 üretici doğruluğunda %92 olarak gerçekleşmiştir. Bu algoritma ile diğer tarım alanları %90’nın üzerinde bir başarı ile haritalanmıştır. Çalışma alanındaki nadas ve toprak yol alanlarının haritalama başarısı üretici doğruluğunda %83, kullanıcı doğruluğunda %94 olarak gerçekleşmiştir. Yapay yüzeylerde ise kullanıcı doğruluğunda %79, üretici doğruluğunda %100 başarı sağlanmıştır. Algoritmanın genel sınıflandırma doğruluğu %91, Kappa değeri 0.87 olarak elde edilmiştir.

Tablo 6.9. Nesne Tabanlı RO algoritması ile elde edilen doğruluk değerleri


Sınıflar	Asma	Diğer Tarım Alanları	Nadas -Yol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	87	6	6	0	99	0.88
Diğer Tarım Alanları	5	117	3	0	125	0.94
Nadas-Yol	3	1	58	0	62	0.94
Yapay Yüzeyler	0	0	3	11	14	0.79
Toplam	95	124	70	11	300	
Üretici Doğruluğu	0.92	0.94	0.83	1.00		
Genel Doğruluk:0.91					Kappa: 0.87	



Şekil 6.14. Nesne tabanlı RO algoritması ile üretilen sınıflandırma haritası

Çalışma kapsamından son olarak nesne tabanlı asmaların haritalanmasında DVM algoritması uygulanmıştır. DVM algoritmasında radyal tabanlı kernel fonksiyonu kullanılmıştır. Bu fonksiyonun uygun C düzenleme parametre değeri veri seti için 100 Gamma değeri 0.001 olarak tespit edilip sınıflandırma işlemi gerçekleştirilmiştir. Elde edilen sonuç harita Şekil 6.15’de gösterilmiştir. Üretilen haritaya ait doğruluk değerleri Tablo 6.10’da verilmiştir. Tablo’da gösterilen değerler irdelendiğinde, asmalara ait kullanıcı doğruluğu %78, üretici doğruluğu %88 olarak elde edilmiştir. DVM algoritması ile diğer tarım alanları %90 üzerinde başarı ile haritalanmıştır. Nadas ve yol alanlarının kullanıcı doğruluğu %93, üretici doğruluğu %73 olarak belirlenmiştir. Yapay yüzeylerin

haritalanmasında ise %79 üzerinde başarı sağlanmıştır. Algoritmanın genel doğruluğu %87, Kappa değeri 0.81 olarak elde edilmiştir.



Şekil 6.15. Nesne tabanlı DVM algoritması ile üretilen sınıflandırma haritası

Tablo 6.10. Nesne Tabanlı RO algoritması ile elde edilen doğruluk değerleri

Sınıflar	Asma	Diğer Tarım Alanları	Nadas -Yol	Yapay Yüzeyler	Toplam	Kullanıcı Doğruluğu
Asma	84	8	15	0	107	0.78
Diğer Tarım Alanları	7	116	1	0	124	0.94
Nadas-Yol	4	0	51	0	55	0.93
Yapay Yüzeyler	0	0	3	11	14	0.79
Toplam	95	124	70	11	300	

Üretici Doğruluğu	0.88	0.94	0.73	1
Genel Doğruluk: 0.87				Kappa: 0.81

7. TARTIŞMALAR

Bu tez çalışması kapsamında PlanetScope görüntülerinden Manisa Saruhanlı ilçesinde araştırma sahası olarak seçilen alanda asmaların haritalanması gerçekleştirilmiştir. Haritalama işleminde uzaktan algılamada bilgi çıkarma işleminde sıklıkla kullanılan nesne tabanlı sınıflandırma ve piksel tabanlı sınıflandırma yaklaşımları kullanılmıştır. Piksel tabanlı sınıflandırma işleminde EÇO, RO, DVM olmak üzere üç algoritma kullanılmıştır. Nesne tabanlı sınıflandırma yaklaşımında ise K-EYK, NB, KA, RO ve DVM algoritmaları kullanılmıştır. Kullanılan bu algoritmaların asmaları haritalamadaki başarıları ve sınıflandırma işleminin genel başarısına ait özet doğruluk tablosu aşağıda verilmiştir (Tablo 7.1).

Tablo 7.1. Asmaların haritalanmasında kullanılan sınıflandırma yaklaşımlarının ve algoritmaların karşılaştırılması

Sınıflandırma Yaklaşımı	Algoritma	Kullanıcı Doğruluğu (%)	Üretici Doğruluğu (%)	Genel Doğruluk (%)	Kappa
Piksel Tabanlı	EÇO	84	85	88	0.82
	RO	85	85	88	0.83
	DVM	81	85	87	0.81
Nesne Tabanlı	K-EYK	85	85	88	0.83
	NB	91	75	83	0.75
	KA	85	80	88	0.82
	RO	88	92	91	0.87
	DVM	78	88	87	0.81

Çalışma kapsamında uygulanan piksel tabanlı sınıflandırma algoritmaları incelendiğinde, kullanılan üç algoritma ile asmaların haritalanmasında %80'nin üzerinde başarı elde edilmiştir. Bu algoritmalarından RO algoritması en yüksek doğruluk veren algoritma olduğu görülmüştür (Tablo 7.1).


Asma alanlarının haritalanmasında nesne tabanlı yaklaşımda kullanılan algoritmalar karşılaştırıldığında NB algoritmasının üretici doğruluğu ve DVM algoritmasının kullanıcı doğruluğu dışında diğer tüm algoritmalarda asmaların belirlenmesinde %80 üzeri başarı sağlanmıştır. Bu algoritmaların genel doğrulukları ve Kappa değerleri incelendiğinde tüm

algoritmalarla genel doęruluk deęerlerinin %80 zerinde olduęu grlmektedir. Kappa deęerlerinde ise sadece NB algoritmasında %80 altında bařarı olduęu grlmřtr. NB algoritması tembel bir ęrenme algoritmasıdır ve kompleks veri setlerinde bařarısız olabilmektedir. Nesne tabanlı uygulanan algoritmalar arasında piksel tabanlı yaklařımda olduęu gibi RO algoritması en yksek doęruluęu vermiřtir.


Kullanılan algoritmaları piksel tabanlı ve nesne tabanlı kullanımlarını karřılařtırdıęımızda Nesne tabanlı sınıflandırmada uygulana RO algoritması piksel tabanlı uygulana RO algoritmasında kullanıcı doęruluęunda %3, retici doęruluęunda %7 oranında daha yksek doęruluk vermiřtir. RO algoritması byk hacimli ve ok deęiřkenli veri setlerinde iyi performans gsteren bir makine ęrenme algoritmasıdır. Bu alıřmada nesne tabanlı sınıflandırma iřleminde kullanılan deęiřken sayısı piksel tabanlı sınıflandırmada kullanılan deęiřken sayısından fazladır. Nesne tabanlı sınıflandırma iřleminde 18 farklı zellik (deęiřken) kullanılırken, piksel tabanlı sınıflandırmada sadece PlanetScope grntsnn 4 bandı kullanılmıřtır. Buradan nesne tabanlı sınıflandırmada kullanılan geometrik ve dokusal deęerlerin doęruluęu artırdıęı grlebilmektedir.

Nesne tabanlı sınıflandırma yaklařımında, dokusal ve geometrik zellikler asma alanları gibi belirli bir dokusu olan alanlarda olumlu sonular vermektedir. alıřma kapsamında yapılan zellik seiminde de hem řekilsel hem de dokusal zellik olmak zere altıřar adet zellięin sınıflandırmada ayırt edici zellikte olduęu grlmřtr (Tablo 6.5).

Piksel tabanlı sınıflandırma iřlemi yksek konumsal znrlkl grntlere uygulandıęında, yapılan sınıflandırma iřlemi sonucunda sonu haritada tuz-biber etkisi adı verilen yanlış sınıflandırılmıř pikseller oluřturabilmektedir. Bu alıřmada asmaların haritalanması iin uygulanan piksel tabanlı  algoritmada da yanlış sınıflandırılmıř piksellerin olduęu grlmřtr. rneęin bir asma parseli iinde piksel-piksel dięer tarım alanı sınıfı grlmřtr. Benzer řekilde dięer tarım alanı sınıfına ait parseller iinde piksel-piksel asma sınıfına ait pikseller grlmřtr. Bu durum nesne tabanlı sınıflandırmada grlmemiřtir (řekil 7.1)



Piksel Tabanlı Sınıflandırma



Nesne Tabanlı Sınıflandırma

Şekil 7.1. *Piksel tabanlı ve Nesne Tabanlı Sınıflandırma tuz-biber etkisi*

PlanetScope uyduları 3 m konumsal çözünürlükte günlük yeryüzüne ait veri üretme kapasitesine sahip bir uydu filosudur. Bu uydular tarımsal ürünlerin takip edilmesi açısından son derece kullanışlı uydu sistemleridir. Bu çalışmada gerek piksel tabanlı gerekse nesne tabanlı sınıflandırma yaklaşımlarında yüksek doğruluk değerleri ile asma parselleri tespit edilmiştir. Üretilen bu haritalar asma parsellerinin zamansal izlenmesi, verim tahmini, hastalık tespiti gibi uygulamalarda kullanılabilir.

Literatürde yapılan çalışmalar incelendiğinde asma alanları için Sentinel ve PlanetScope uydu sistemleri ile ilgili çalışmaların sınırlı olduğu görülmektedir. Bu çalışmalarda genellikle NDVI karşılaştırılması yapılarak bu sistemlerin asmaların zamansal izlenmesinde kullanılabilirliği araştırılmıştır. Bu çalışmada literatürden farklı olarak PlanetScope uydu sistemlerinin asmaların haritalanmasındaki başarısı araştırılmıştır. Elde edilen sonuçlar bu uydu sistemlerinin asma parsellerinin haritalanmasında başarılı şekilde kullanılabileceğini göstermektedir.

Yapılan çalışmada asma parsellerinin belirlenmesi için farklı sınıflandırma yaklaşımları ve algoritmaları kullanılmıştır. Çalışma sahasında asma parselleri bir birine bitişik şekilde konumlanmaktadır. Kullanılan uydu sistemleri ve yöntemleri parselleri belirlemiştir. Ancak özellikle bitişik parsellerde kullanılan uydu sisteminin çözünürlüğü yetersiz kalmaktadır. Bitişik parsellerde PlanetScope'dan daha yüksek çözünürlüklü görüntüler kullanılması bu parselleri tespit etmedeki başarıyı arttıracaktır.

Asma alanlarının zamansal izlenmesi için gerek NDVI analizinde gerekse yapılan sınıflandırma çalışmalarında PlanetScope görüntüleri zamansal çözünürlük açısından son derece kullanışlı sistemlerdir. Bir araştırma sahasında kesin sınırları ayırt edilemeyen asma parselleri yüksek konumsal çözünürlüklü görüntülerden belirlendikten sonra PlanetScope uyduları ile zamansal olarak başarılı şekilde izlenebilir. Özellikle ürün verimi, hastalık tespiti gibi çalışmalarda bu sistemler rahatlıkla kullanılabilir.

8. SONUÇ VE ÖNERİLER

Bu çalışmada piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımları kullanılarak, farklı sınıflandırma algoritmaları ile PlanetScope görüntülerinin asmaları haritalamadaki başarısı araştırılmıştır. Yapılan farklı sınıflandırma yaklaşımında RO algoritması asmaları haritalamada en başarılı algoritma olmuştur. RO algoritması özelinde piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımları karşılaştırıldığında nesne tabanlı sınıflandırmanın daha başarılı sonuç verdiği görülmüştür. Ayrıca. Nesne tabanlı sınıflandırma, yüksek konumsal çözünürlük verilere piksel tabanlı sınıflandırma uygulandığında ortaya çıkan ve tuz-biber etkisi adı verilen yanlış piksel sınıflandırması etkisini azaltmıştır.

Yapılan çalışmada asma parsellerinin tekil olarak haritalanması yapılamamıştır. Bunun en temel nedeni 3 m konumsal çözünürlüklü görüntülerde özellikle bitişik parsellerde sınırların belirli olmamasıdır. Bu tip parsellerde parsel sınırları bir defa yüksek konumsal belirlendikten sonra, parsellerin zamansal izlenmesi, asmaların sağlık durumu, verim analizleri PlanetScope görüntülerinden tespit edilebilirler.

KAYNAKÇA

- Akar, Ö., and Güngör, O. (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. *Jeodezi ve Jeoinformasyon Dergisi*, 139-146
- Al-Doski, J., Mansori, S.B., and Shafri, H.Z.M. (2013). Image classification in remote sensing. *Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia*, 3
- Aspinall, R. (1992). An inductive modelling procedure based on Bayes' theorem for analysis of pattern in spatial data. *International Journal of Geographical Information Systems*, 6, 105-121
- Báez-González, A.D., Chen, P.y., Tiscareño-López, M., and Srinivasan, R. (2002). Using satellite and field data with crop growth modeling to monitor and estimate corn yield in Mexico. *Crop Science*, 42, 1943-1949
- Belgiu, M., and Drăguț, L. (2014). Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 67-75
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32
- Campos, J., García-Ruiz, F., and Gil, E. (2021). Assessment of Vineyard Canopy Characteristics from Vigour Maps Obtained Using UAV and Satellite Imagery. *Sensors*, 21, 2363
- Curran, P. J. (1985). Principles of remote sensing. Longman Inc.
- Di Gennaro, S.F., Dainelli, R., Palliotti, A., Toscano, P., and Matese, A. (2019). Sentinel2 validation for spatial variability assessment in overhead trellis system viticulture versus UAV and agronomic data. *Remote Sensing*, 11, 2573

- Ekercin, S. (2007). Uzaktan Algılama Ve Coğrafi Bilgi Sistemleri Entegrasyonu İle Tuz Gölü Ve Yakın Çevresinin Zamana Bağlı Değişim Analizi, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü
- Esemen K. (2011) Uydu Görüntüleri ile Orman Yangını Analizi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Bilişim Enstitüsü.
- Govedarica A, M., RISTIĆ, A., JOVANOVIĆ, D., HERBEI, M., and SALA, F. (2015). Object Oriented Image Analysis in Remote Sensing of Forest and Vineyard Areas. *Bulletin of the University of Agricultural Sciences & Veterinary Medicine ClujNapoca. Horticulture*, 72
- Happ, P., Ferreira, R.S., Bentes, C., Costa, G., and Feitosa, R.Q. (2010). Multiresolution segmentation: a parallel approach for high resolution image segmentation in multicore architectures. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, C7
- Hernandez, I., Benevides, P., Costa, H., and Caetano, M. (2020). Exploring SENTINEL2 for Land Cover and Crop Mapping in Portugal. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 83-89
- Jensen, J.R. (1996). *Introductory digital image processing: a remote sensing perspective*. Prentice-Hall Inc.
- Johnson, L., Roczen, D., Youkhana, S., Nemani, R., and Bosch, D. (2003). Mapping vineyard leaf area with multispectral satellite imagery. *Computers and electronics in agriculture*, 38, 33-44
- Karadağ, K., & Taşalın, R. (2016). Biber Bitkisinden Alınan Spektral Yansımaların Yapay Sinir Ağları Kullanarak Hastalık Tespiti. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi, 3(5), 50-59.

- Karakizi, C., Oikonomou, M., and Karantzas, K. (2016). Vineyard detection and vine variety discrimination from very high resolution satellite data. *Remote Sensing*, 8, 235
- Kavak, K. Ş. (1998). Uzaktan algılamanın temel kavramları ve jeolojideki uygulama alanları. *Jeoloji Mühendisliği Dergisi*, (52).
- Kim, W., and Liang, S. (2016). Unsupervised classification. *International Encyclopedia of Geography: People, the Earth, Environment and Technology: People, the Earth, Environment and Technology*, 1-5
- Lacar, F., Lewis, M., and Grierson, I. (2001). Use of hyperspectral imagery for mapping grape varieties in the Barossa Valley, South Australia. In, *IGARSS 2001. Scanning the Present and Resolving the Future. Proceedings. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No. 01CH37217)* (pp. 28752877): IEEE
- Mulla, D.J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114, 358-371
- Musaoğlu, N. Elektro-optik ve mikrodalga algılayıcılardan elde edilen uydu verilerinden orman alanlarında meşcere tiplerinin ve yetiştirme ortamı birimlerinin belirlenme olanakları. 1999. Doktora Tezi, İstanbul Teknik Üniversitesi. Fen Bilimleri Enstitüsü.
- Örmeci, C. (1987) Uzaktan Algılama (Temel Esaslar ve Algılama Sistemleri), İstanbul Teknik Üniversite Matbaası, İstanbul
- Pádua, L., Adão, T., Hruška, J., Guimarães, N., Marques, P., Peres, E., and Sousa, J.J. (2020). Vineyard Classification Using Machine Learning Techniques Applied to RGB-UAV Imagery. In, *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium* (pp. 6309-6312): IEEE

- Richards, J.A. (2013). Clustering and unsupervised classification. *Remote Sensing Digital Image Analysis* (pp. 319-341): Springer
- Roli, F., and Fumera, G. (2001). Support vector machines for remote sensing image classification. In, *Image and Signal Processing for Remote Sensing VI* (pp. 160166): International Society for Optics and Photonics
- Saghari, M., Dizbadi, M., and Taghipour, M. (2018). Classification of Satellite Imagery Data to Estimate Cultivated Areas of Grape Farms. *World*, 7, 102-105
- Saritas, M.M., and Yasar, A. (2019). Performance analysis of ANN and Naive Bayes classification algorithm for data classification. *International Journal of Intelligent Systems and Applications in Engineering*, 7, 88-91
- Sawasawa, H. (2003). Crop yield estimation: Integrating RS, GIS, and management factors. *International Institute for Geo-information Science and Earth Observation, Enschede The Netherlands*
- Sertel, E., Seker, D.Z., Yay, I., Ozelkan, E., SAGLAM, M., BOZ, Y., and GUNDUZ, A. (2012). Vineyard mapping using remote sensing technologies. In, *Conference paper, FIG Working Week 2012, Knowing to manage the territory, protect the environment, evaluate the cultural heritage*
- Sozzi, M., Kayad, A., Marinello, F., Taylor, J., and Tisseyre, B. (2020). Comparing vineyard imagery acquired from Sentinel-2 and Unmanned Aerial Vehicle (UAV) platform. *OENO One*, 54, 189-197
- Sun, L., Gao, F., Anderson, M.C., Kustas, W.P., Alsina, M.M., Sanchez, L., Sams, B., McKee, L., Dulaney, W., and White, W.A. (2017). Daily mapping of 30 m LAI and NDVI for grape yield prediction in California vineyards. *Remote Sensing*, 9, 317
- Sunar F., Özkan S., Osmanoğlu, B. (2011) Uzaktan Algılama Ders Kitabı Anadolu üniversitesi Açıköğretim yayınları Eskişehir.

Uça Avcı, Z.D., Ok, A.Ö., Berberoğlu, S. (2017). Sınıflandırma – Temel Teknikler. A.Ö. Ok, Digital Görüntü İşleme (pp. 213-237). Eskişehir: Anadolu Üniversitesi.

Vibhute, A.D., and Gawali, B.W. (2013). Analysis and modeling of agricultural land use using remote sensing and geographic information system: a review. *International Journal of Engineering Research and Applications*, 3, 081-091

Weston, J., Mukherjee, S., Chapelle, O., Pontil, M., Poggio, T., and Vapnik, V. (2000). Feature selection for SVMs

Wójtowicz, M., Wójtowicz, A., and Piekarczyk, J. (2016). Application of remote sensing methods in agriculture. *Communications in Biometry and Crop Science*, 11, 3150

İnternet Kaynakları http-1: What is Remote Sesning?
<https://earthdata.nasa.gov/learn/backgrounders/remotesensing> http-2: Manisa
Coğrafyası, https://www.manisa.bel.tr/s23_manisa-cografyasi.aspx http-3: Manisa
üzümü, <https://manisa.tarimorman.gov.tr/Menu/32/Manisa-Uzumu>