

T.C.  
AKDENİZ ÜNİVERSİTESİ



**İNSANSIZ HAVA ARACI VE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU  
VERİLERİNİN DEĞERLENDİRİLMESİNDE PİKSEL VE NESNE TABANLI  
SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

**Mesut ÇOŞLU**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ**

**ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**MAYIS 2019**

**ANTALYA**

T.C.  
AKDENİZ ÜNİVERSİTESİ



İNSANSIZ HAVA ARACI VE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU  
VERİLERİNİN DEĞERLENDİRİLMESİNDE PİKSEL VE NESNE TABANLI  
SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Mesut ÇOŞLU

FEN BİLİMLERİ ENSTİTÜSÜ

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

MAYIS 2019

ANTALYA

T.C.  
AKDENİZ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

İNSANSIZ HAVA ARACI VE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU  
VERİLERİNİN DEĞERLENDİRİLMESİNDE PİKSEL VE NESNE TABANLI  
SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Mesut ÇOŞLU

UZAKTAN ALGILAMA VE COĞRAFİ BİLGİ SİSTEMLERİ

ANABİLİM DALI

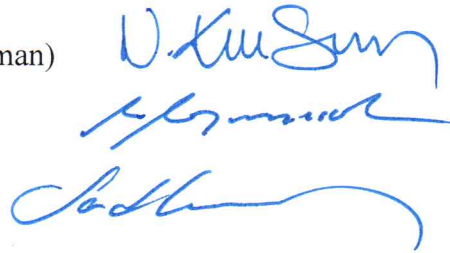
YÜKSEK LİSANS TEZİ

Bu tez 31.05./2019... tarihinde jüri tarafından Oybirliği / ~~Oyçokluğu~~ ile kabul edilmiştir.

Prof. Dr. Namık Kemal SÖNMEZ (Danışman)

Prof. Dr. Levent BAŞAYIĞIT

Dr. Öğr. Üyesi Serdar SELİM



## ÖZET

# İNSANSIZ HAVA ARACI VE YÜKSEK ÇÖZÜNÜRLÜKLÜ UYDU VERİLERİNİN DEĞERLENDİRİLMESİNDE PİKSEL VE NESNE TABANLI SINIFLANDIRMA YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Mesut ÇOŞLU

Yüksek Lisans Tezi, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Danışman: Prof. Dr. Namık Kemal SÖNMEZ

Mayıs 2019; 53 sayfa

Uzaktan algılama teknolojileri son yıllarda gerek uydu, uçak ve yer temelli sistemler gerekse bilgisayar yazılım ve donanımlarındaki gelişmeler neticesinde sıkça kullanılır hale gelmiştir. Bu teknolojik gelişmeler ışığında daha önceleri sadece güvenlik amacıyla kullanılan insansız hava araçları artık pek çok nedenle sivil amaçlı olarak da kullanılmaktadır. İnsansız hava araçlarının kullanımını yaygınlaştıran nedenlerin başında insan hayatını riske etmemesi gelmektedir. Bunun yanı sıra insanlı hava araçlarına göre maliyetinin düşük olması ve yüksek manevra yeteneği de en önemli avantajları arasında yer almaktadır.

Günümüzde doğa bilimleri çalışmalarında uzaktan algılama verilerinden elde edilen görüntülerden analizler yapabilmeyi sağlayan sınıflandırma çalışmaları bu teknolojik gelişmelerle farklı bir boyut kazanmıştır. Bu kapsamda piksel tabanlı sınıflandırma işlemlerinin yanı sıra özellikle yüksek çözünürlüklü veriler kullanarak yapılan görüntü analizi işlemlerinde nesne tabanlı sınıflandırma yöntemi de sıkça kullanılmaktadır.

Akdeniz Üniversitesi merkez yerleşke arazisinde gerçekleştirilen bu çalışmada kullanılan temel veriler, insansız hava aracına (İHA) monte edilmiş elektromanyetik spektrumun görünür ve yakın kızılötesi bölgesinden elde edilen güncel veriler ve çalışma alanına ait yüksek çözünürlüklü WorldView-4 (WV4) uydu verileridir. Bu kapsamda çalışma alanı, İHA ve yüksek çözünürlüklü WV4 uydu verileri kullanılarak, piksel tabanlı ve nesne tabanlı sınıflandırma yöntemleriyle analiz edilmiştir. Çalışma iki temel aşamadan oluşmaktadır. Bunlar veri toplama ve hazırlık ile sınıflandırma aşamalarıdır. Çalışmanın ilk aşamasında yakın tarihli İHA ve uydu verileri temin edilmiştir. Bu aşamada verilere görüntü ön işleme ve görüntü zenginleştirme teknikleri uygulanarak analize hazır hale getirilmiştir. İkinci aşamada ise farklı sınıflandırma teknikleri ile bu veriler analiz edilmiştir.

Yapılan bu çalışma sonucunda, alandaki arazilerin kullanım türleri farklı veriler ile piksel tabanlı sınıflandırma ve yeni bir yaklaşım olan nesne tabanlı sınıflandırma yöntemine göre ayrı ayrı analiz edilmiş ve elde edilen sonuçlar karşılaştırılarak hangi yöntemin başarılı olduğu ortaya konmuştur. Elde edilen bulgular neticesinde piksel tabanlı sınıflandırma yönteminde en yüksek genel doğruluk değeri % 54.92 ile WV4 uydusundan, nesne tabanlı sınıflandırma yönteminde ise % 75.40 ile İHA verilerinden elde edilmiştir.

**ANAHTAR KELİMELEER:** İHA, Nesne tabanlı sınıflandırma, Pıksel tabanlı sınıflandırma, Uzaktan algılama, WV4

**JÜRİ:** Prof. Dr. Namık Kemal SÖNMEZ

Prof. Dr. Levent BAŞAYİĞİT

Dr. Öğr. Üyesi Serdar SELİM

## **ABSTRACT**

### **COMPARISON OF PIXEL AND OBJECT-BASED CLASSIFICATION METHODS IN THE EVALUATION OF UNMANNED AERIAL VEHICLE AND HIGH RESOLUTION SATELLITE DATA**

**Mesut OŞLU**

**MSc Thesis in Remote Sensing and Geographic Information Systems Department**

**Supervisor: Prof. Dr. Namık Kemal SÖNMEZ**

**May 2019; 53 pages**

Remote sensing technologies have been used frequently in recent years as a result of developments in both satellite, aircraft and ground based systems as well as computer software and hardware. In the light of these technological developments, unmanned aerial vehicles, previously used for safety purposes, have been also used for civilian purposes for many reasons. The reason for the widespread use of unmanned aerial vehicles is not to risk human life. Besides, in comparison with manned aircraft, unmanned aerial vehicles have more important advantages such as low cost and high manoeuvre ability.

Nowadays, classification studies, which provide analysis of images obtained from remote sensing data in natural sciences studies, have gained a different dimension with these technological developments. In this context, in addition to pixel-based classification processes, object-based classification method is frequently used in image analysis processes using high resolution data.

The main data used in this study conducted on the central campus of Akdeniz University is the current data obtained from the visible and near infrared region of the electromagnetic spectrum mounted on unmanned aerial vehicle (UAV) and the high resolution WorldView-4 (WV4) satellite data of the study area. In this context, the study area was analysed with pixel-based and object-based classification methods using UAV and high resolution WV4 satellite data. The study consists of two basic stages. These are the stages of data collection and preparation and classification. In the first stage of the study, recently unmanned aerial vehicle and satellite data were obtained. At this stage, the data was prepared by using the image pre-treatment and image enrichment techniques. In the second stage, these data were analysed with different classification techniques.

As a result of this study, the usage types of the lands in the area were analysed separately according to different data using pixel-based classification and a new approach known as object-based classification method, and the results were compared and it was revealed which method was more successful. As a result of the findings, while the highest overall accuracy value with pixel-based classification was found 54.92% using WV4, 75.40% value was found with object-based classification using unmanned aerial vehicle data.

**KEYWORDS:** Object-based classification, Pixel-based classification, Remote sensing, UAV, WV4

**COMMITTEE:** Prof. Dr. Namık Kemal SÖNMEZ  
Prof. Dr. Levent BAŞAYIĞIT  
Asst. Prof. Dr. Serdar SELİM

## ÖNSÖZ

Lisansüstü eğitim sürecimin gerek ders gerekse tez aşamasında akademik bilgi ve birikimi ile çalışmalarına katkıda bulunan, tez konusunun seçiminden hazırlanmasına kadar her an desteğini hissettiğim kıymetli hocam, Prof. Dr. Namık Kemal SÖNMEZ'e en içten teşekkürlerimi sunuyorum.

Bu çalışma döneminde her türlü fedakârlıktan kaçınmayan, yüksek hoşgörü ve anlayışa sahip olduğunu düşündüğüm aynı zamanda büyük manevi desteğini hissettiğim sevgili eşim Bahar ile çocuklarım Mehmet Ata ve Türkay Efe'ye büyük minnet borçluyum.



## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ .....	v
AKADEMİK BEYAN .....	viii
SİMGELER VE KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ .....	xii
1. GİRİŞ.....	1
1.1. Uzaktan Algılama .....	2
1.2. Elektromanyetik Enerji .....	3
1.3. Elektromanyetik Işınımın Yeryüzü Cisimleri İle Etkileşimi .....	5
1.4. Sayısal Görüntü İşleme .....	6
1.4.1. Ön işleme .....	6
1.4.2. Görüntü zenginleştirme.....	8
1.4.3. Sınıflandırma.....	8
2. KAYNAK TARAMASI.....	10
3. MATERYAL VE METOT.....	18
3.1. Çalışma Alanı.....	18
3.2. Çalışmada Kullanılan Veriler .....	20
3.3. Metot .....	23
3.3.1. Veri toplama ve hazırlık.....	24
3.3.2. Sınıflandırma.....	34
4. BULGULAR VE TARTIŞMA .....	36
4.1. Piksel Tabanlı Sınıflandırma.....	36
4.1.1. Kontrolsüz sınıflandırma .....	36
4.1.2. Kontrollü sınıflandırma.....	38
4.2. Nesne Tabanlı Sınıflandırma .....	39
4.2.1. Dört band görüntünün sınıflandırılması.....	39
4.2.2. Altı band görüntünün sınıflandırılması.....	41
4.3. Doğruluk Değerlendirmesi.....	42
5. SONUÇLAR .....	47

6. KAYNAKLAR.....	49
ÖZGEÇMİŞ	

## AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “İnsansız Hava Aracı Ve Yüksek Çözünürlüklü Uydu Verilerinin Değerlendirilmesinde Pikel Ve Nesne Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

31/05/2019

Mesut ÇOŞLU



## SİMGELER VE KISALTMALAR

### **Simgeler**

cm : Santimetre

da : Dekar

ft : Fit

gr : Gram

ha : Hektar

km : Kilometre

km<sup>2</sup> : Kilometrekare

m : Metre

mm:: Milimetre

nm : Nanometre

µm: Mikrometre

“01.01” Ondalık Ayırıcı

### **Kısaltmalar**

AGL : Above Ground Level

CBS : Coğrafi Bilgi Sistemleri

GPS : Global Positioning System

DT : Decision Tree

İHA : İnsansız Hava Aracı

KNN : K Nerarest Neighbour

MS : Multispektral

NDVI : Normalized Difference Vegetation Index

NIR : Near Infrared

PAN : Pankromatik

RGB : Red-Green-Blue

RGN : Red-Green-NIR

RT : Random Trees

SAVI : Soil Adjusted Vegetation Index

SHT : Sivil Havacılık Talimatı

SVM : Support Vector Machine

SWIR : Short-wave Infrared

UAV : Unmanned Aerial Vehicle

UTM : Universal Transverse Mercator

WGS : World Geodetic System

WV4 : WorldView-4

## ŞEKİLLER DİZİNİ

Şekil 1.1. Yer kaynaklarının uzaktan algılanması .....	3
Şekil 1.2. Elektromanyetik dalga .....	3
Şekil 1.3. Enerji-dalga boyu ilişkisi.....	4
Şekil 1.4. Elektromanyetik spektrum.....	5
Şekil 1.5. Bitki örtüsü, toprak ve su için tipik yansımaya eğrileri .....	5
Şekil 3.1. Çalışma alanı .....	19
Şekil 3.2. Çalışmada kullanılan İHA, RGB kamera, NIR kamera.....	20
Şekil 3.3. WorldView-4 uzay aracı.....	22
Şekil 3.4. Yöntem akış şeması .....	24
Şekil 3.5. Inspire 2 uçuş planı.....	25
Şekil 3.6. Inspire 2'ye monte edilmiş survey 3 kamera .....	26
Şekil 3.7. MAPIR kamera yansıtma kalibrasyonu zemin hedef paketi (V2).....	27
Şekil 3.8. Kalibrasyon amacıyla kullanılan Survey 3 kamera referans görüntüsü .....	28
Şekil 3.9. Kalibrasyon işlemi .....	28
Şekil 3.10. İnsansız hava aracı layer stack işlemi.....	29
Şekil 3.11. NDVI ve SAVI görüntüleri .....	30
Şekil 3.12. Çalışma alanından bir bölgeye ait WV4 pansharpened işlemi .....	32
Şekil 3.13. Yer gerçeği verisi.....	33
Şekil 3.14. Segmentasyon işlemi sonucu.....	35
Şekil 4.1. Piksel tabanlı (kontrolsüz) sınıflandırma sonuçları .....	37
Şekil 4.2. Piksel tabanlı (kontrollü) sınıflandırma sonuçları .....	38
Şekil 4.3. Nesne tabanlı (dört band) sınıflandırma sonucu.....	40
Şekil 4.4. Nesne tabanlı (altı band) sınıflandırma sonucu .....	41

## ÇİZELGELER DİZİNİ

Çizelge 3.1. Zenmuse X4S kameranın özellikleri .....	21
Çizelge 3.2. Survey 3 kameranın özellikleri .....	21
Çizelge 3.3. WorldView-4 uydusunun teknik özellikleri .....	23
Çizelge 4.1. Kontrolsüz sınıflandırma sonucu alansal dağılımlar .....	37
Çizelge 4.2. Kontrollü sınıflandırma sonucu alansal dağılımlar.....	39
Çizelge 4.3. Nesne tabanlı sınıflandırma sonucu alansal dağılımlar (dört band) .....	40
Çizelge 4.4. Nesne tabanlı sınıflandırma sonucu alansal dağılımlar (altı band).....	42
Çizelge 4.5. Doğruluk analizi sonuçları.....	43
Çizelge 4.6. İnsansız hava aracı sınıflandırma sonuçlarının alansal dağılımı .....	44
Çizelge 4.7. WorldView-4 sınıflandırma sonuçlarının alansal dağılımı.....	45

## 1. GİRİŞ

Yeryüzünden yansıyan enerjinin algılanması ve işlenmesinde kullanılan uzaktan algılama teknolojisine veri sağlayan temel kaynak uydulardır. Günümüzde çok farklı özelliklere sahip olan uydular, uzaktan algılama çalışmalarında yaygın olarak kullanılmaktadır. Bu teknolojiye her ne kadar uydular ön planda olsa da, son yıllarda drone olarak da bilinen insansız hava araçları (İHA)'nın kullanımı tüm dünyada ve hatta ülkemizde giderek artmaktadır. İnsansız hava aracı kullanımı ilk yıllarda her ne kadar askeri amaçlı olsa da artık günümüzde sivil amaçlı olarak da sıkça kullanılmaktadır. İnsansız hava aracı kullanımının yaygınlaşmasındaki ana nedenler maliyetinin düşük olması, yüksek hareket kabiliyeti ve elbette en önemlisi insansız olarak kullanılmasıdır.

Arazi örtüsü ve arazi kullanımının belirlenmesinde günümüz teknolojisi büyük avantajlar sağlamaktadır. Bu maksatla kullanılan sınıflandırma yöntemlerinden olan nesne tabanlı sınıflandırma yöntemi ile sadece pikseller değil, onların yerine piksellerin rengi, sıklığı ve komşuluğu gibi birtakım fonksiyonlar kullanılarak yüksek çözünürlüklü verilerde haritaların üretimi mümkün olabilmektedir (Bayburt 2009).

Görüntüdeki tematik bilgiyi oluşturan anlamlı örüntü gruplarının belirlenmesi işlemi olan sınıflandırmanın en yaygın kullanım türü piksel tabanlı sınıflandırmadır. Bu sınıflandırma yönteminde bilinmeyen piksel bu pikselin en büyük benzerlik değerine sahip olduğu sınıfa atanır. Ancak son yıllarda sınıflandırma işleminde sadece görüntüdeki spektral bilgiyi değil piksellerin diğer bazı özelliklerini de kullanan yöntem olan nesne tabanlı sınıflandırmanın kullanımı da artmıştır. Nesne tabanlı sınıflandırmada ana eleman piksellerden oluşan nesnelere (Sunar vd. 2013). Bu sınıflandırma yöntemi segmentasyon ve sınıflandırma temel aşamalarından oluşmaktadır. Segmentasyon aşamasında uygun segmentasyon algoritmaları kullanılarak görüntü bölütlenir ve nesnelere oluşturulur. Sınıflandırma aşamasında ise segmentasyon işlemi sonucu elde edilen görüntü nesnelere üzerinden kural setleri oluşturularak temel ya da gelişmiş sınıflandırıcı algoritmalar (SVM, RT, DT gibi) yardımıyla sınıflandırma işlemi gerçekleştirilir.

Piksel tabanlı sınıflandırmalar orta çözünürlüklü verilerde önemli avantajlar sağlamaktadır. Bununla birlikte sınıflandırma sonuçlarının doğruluğunun test edilmesi ve sonuçların tutarlılığının ortaya konulması amacı ile bu sınıflandırma yönteminde farklı çalışma alanlarında daha fazla uygulamaların yapılması gereği bulunmaktadır (Bayburt 2009). Orta çözünürlükten yüksek çözünürlüklü uydu görüntüsüne geçildiğinde ise güçlü nesne tabanlı sınıflandırma metodlarının gelişimi geleneksel piksel tabanlı metotlara göre daha geçerli bir alternatif sağlamaktadır (Whiteside vd. 2005).

Bu çalışma ile İHA'dan elde edilen güncel veriler ve çalışma alanına ait yüksek çözünürlüklü uydu verileri kullanarak, piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması ve sınıflandırma sonuçlarının değerlendirilmesi amaçlanmıştır. Çalışma veri toplama ve hazırlık ile sınıflandırma temel aşamalarından oluşmaktadır. İlk aşama olan veri toplama ve hazırlık aşamasında İHA verileri, yüksek çözünürlüklü uydu verileri ve yerleşke verileri temin edilerek analize hazır hale getirilmiştir. İkinci aşamada, görüntüler üzerinden piksel tabanlı ve nesne tabanlı sınıflandırma işlemleri yapılmıştır. Çalışmada son olarak piksel tabanlı ve yeni bir



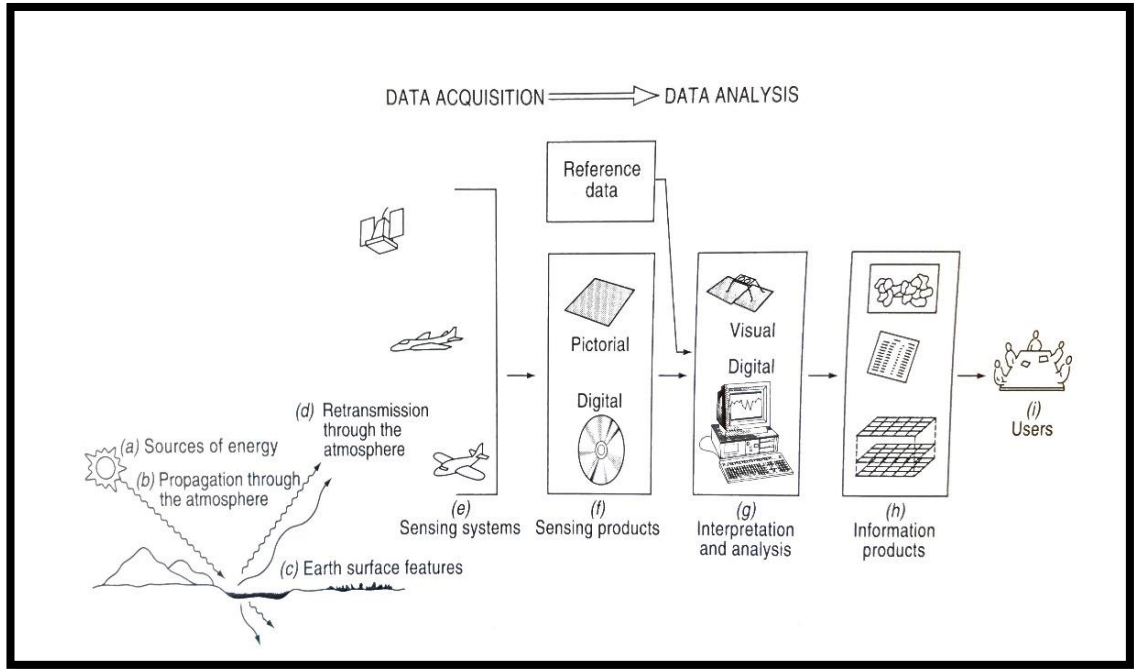
yaklaşım olan nesne tabanlı sınıflandırma yöntemine göre ayrı ayrı analiz edilen alandaki arazilerin kullanım türleri ve elde edilen sonuçlar karşılaştırılarak hangi yöntemin başarılı olduğu farklı yüksek çözünürlükteki veriler üzerinden ortaya konmuştur. Yürütülen bu çalışmada hem İHA hem de WV4 verilerinin kullanılması ve ayrıca bu verilerin farklı sınıflandırma teknikleri ile değerlendirilmesi, çalışmanın özgün yanını ortaya koymaktadır.

### 1.1. Uzaktan Algılama

Genel olarak resimler, nesnelere arasındaki konumlar, boyutlar ve karşılıklı ilişkiler hakkında net bilgiler verirler. Resimler, doğası gereği nesnelere olarak tanıyabileceğimiz şeyler hakkındaki bilgileri gösterirler. İnsanlar bu tür görüntülerden bilgi edinme konusunda yüksek bir yeterliliğe sahip oldukları için, görsel olarak karmaşık olan sahneleri bile yorumlamada çok az zorluk çekerler. Sadece bilgisayar programlarını kullanarak bu yetenekleri arttırmaya çalıştığımızda yeteneklerimizin bu tür karmaşık bilgileri elde etmek için ne kadar güçlü olduğunu anlayabiliriz. Bu nedenle, her resmin en azından bin kelimenin anlamını distile ettiği söylenebilir. Uzaktan algılama yoluyla temin edilen görüntüler, Dünya yüzeyinin incelenmesi için benzersiz avantajlar sunan önemli özelliklere sahiptir. Bu sayede izole noktalar yerine desenleri ve başka türlü bağımsız görünen özellikler arasındaki ilişkileri görmek mümkündür. Uzaktan algılanan görüntülerin, günlük deneyimde karşılaşılan görüntülerden farklı nitelikleri bulunmaktadır. Bunlardan en önemlileri, bu görüntülerin farklı ölçek ve çözünürlükte veriler olabilmeleri ile elektromanyetik spektrumun farklı bölgelerinden temin edilebilmeleridir (Campbell and Wynne 2011).

Uzaktan algılama teknolojisi, cisimlere fiziksel temasta bulunmaksızın, bir aygıt kullanılarak cisimler hakkında fikir elde etme bilim ve sanatı olarak tanımlanmaktadır. Uzaktan algılama çalışmaları, farklı algılayıcılar kullanarak bilgi elde edilecek cisim hakkında gerekli olan veriyi uzaktan toplamak esasına dayanır. Bu kapsamda uzaktan algılama iki temel süreçten oluşmaktadır. Bunlar, veri kazanımı ve veri analizidir (Şekil 1.1). İlk temel süreç olan veri kazanım sürecinin bileşenleri, enerji kaynağı, enerji-atmosfer etkileşimi, enerji-yeryüzü etkileşimi, enerjinin atmosferden tekrar iletimi, algılama sistemleri ve algılama sonucu elde edilen basılı ya da sayısal algılama ürünleridir. İkinci temel süreç olan veri analizi aşamasında ise, algılanan ürünlerin bazı programlar yardımıyla analizi gerçekleştirilir (Lillesand vd. 2004).


Bu çalışma, uzaktan algılama çatısı altında uzaktan algılamanın temellerini kullanarak, özellikle görüntüler üzerinden bir sınıflandırma yapmakta ve farklı görüntüleri farklı yöntemlerle sınıflandırarak karşılaştırmaktadır.



Şekil 1.1. Yer kaynaklarının uzaktan algılanması (Lillesand vd. 2004)

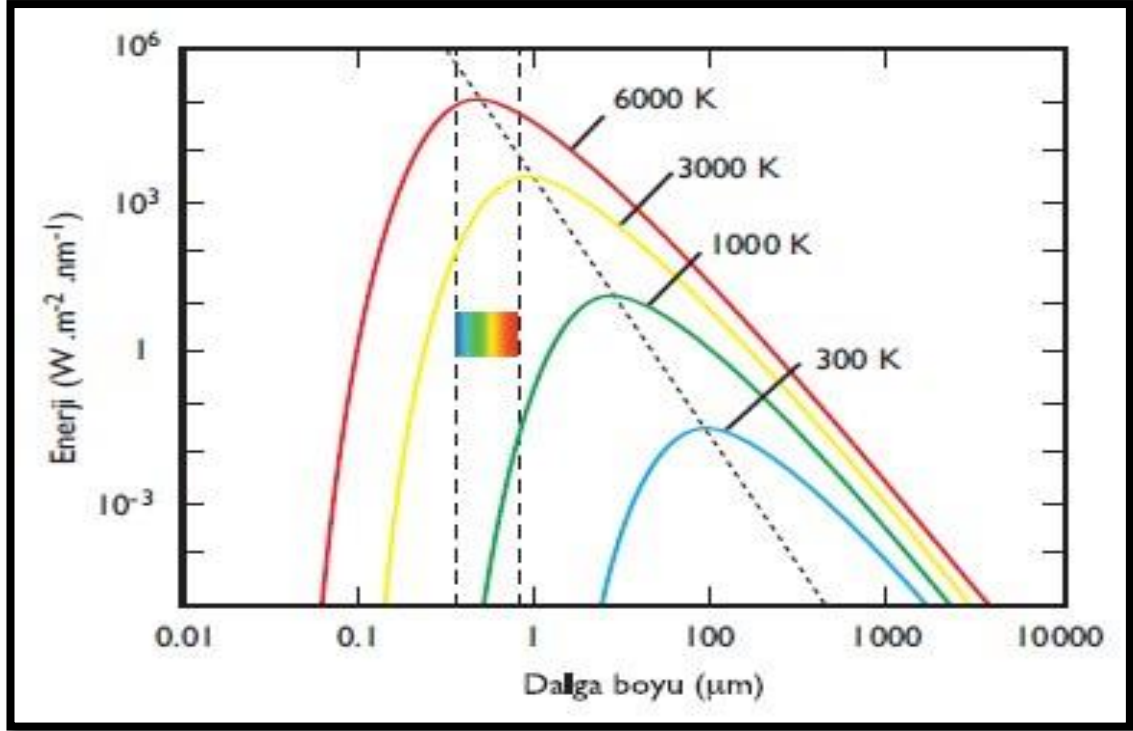
## 1.2. Elektromanyetik Enerji

Elektromanyetik enerji biçimleri görünür ışık, radyo dalgaları, mor ötesi ışınlar, ısıyan ısı ve X ışınları olup görünür ışık, insanoğlunun spektrumunda çıplak gözle algılayabildiği küçük bir bölümünü oluşturmaktadır (Lillesand vd. 2004). Şekil 1.2’de de görüldüğü gibi bu enerjilerin tümü birbirine benzer olarak temel dalga teorisine uygun olarak ilerlemektedir (Sunar vd. 2013). Bu kuram ışık hızında ve sinüs eğrisi şeklinde hareket eden enerjiyi tanımlar. Komşu iki dalganın tepe noktaları arasındaki uzaklık dalga boyu, birim zamanda aynı noktadan geçen dalga tepesi sayısı ise frekans olarak ifade edilmektedir (Lillesand vd. 2004).



Şekil 1.2. Elektromanyetik dalga (Sunar vd. 2013)


Elektromanyetik ışınının yeryüzündeki nesnelere etkileşimi parçacık formunda kuantum teorisi ile ifade edilip enerji denklemiyle açıklanmaktadır. Enerji, frekansla doğru ve dalga boyu ile ters orantılı olduğundan Şekil 1.3’de de görüldüğü gibi dalga boyu artarken enerjide bir azalma olmaktadır (Sunar vd. 2013).



**Şekil 1.3.** Enerji-dalga boyu ilişkisi (Sunar vd. 2013)

Uzaktan algılamada elektromanyetik dalgaların sınıflandırılması genellikle elektromanyetik spektrumdaki konumlarına göre yapılmaktadır. Elektromanyetik spektrumda iki farklı spektral bölgenin arasında keskin bir sınır bulunmamaktadır. Şekil 1.4’te de olduğu gibi spektrumda bölümlerin oluşması farklı algılama tekniklerinden kaynaklanmaktadır (Lillesand vd. 2004). Uzaktan algılamada  $10^{10}$  µm dalga boylarından (kozmik)  $10^{-10}$ µm dalga boylarına (radyo) kadar olan spektrumun özellikle 0.3-15 µm arasındaki optik dalga boyları ile 1-1000 mm arasındaki mikrodalga bölgeleri ile çalışılmaktadır (Sunar vd. 2013).

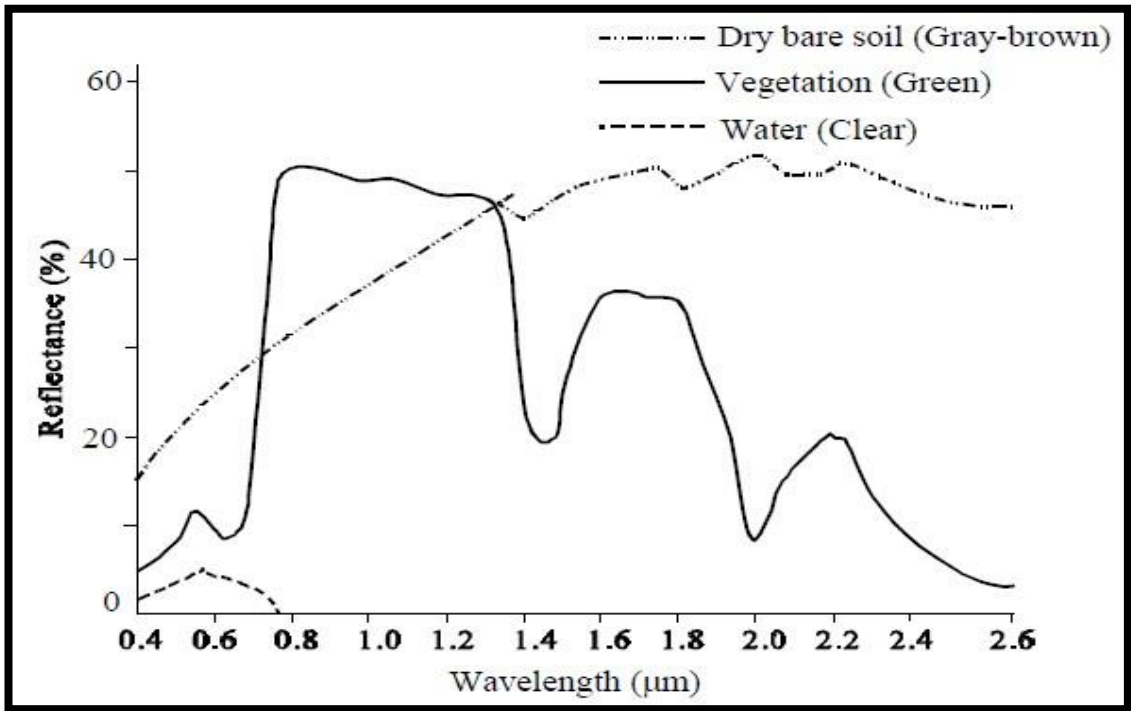
Bu çalışmada elde edilen görüntüler temelde çalışma alanındaki çeşitli arazi kullanımlarını piksel ve nesne tabanlı olarak tanımlamaktadır. Her bir arazi kullanımının elektromanyetik dalga boyları, görüntüleri tanımlamada önemli bir ayırım anahtarı olduğu için görüntü sınıflandırmada yansıma değerleri ve elektromanyetik enerji önem taşımaktadır.



Şekil 1.4. Elektromanyetik spektrum (Lillesand vd. 2004)

### 1.3. Elektromanyetik Işınımın Yeryüzü Cisimleri İle Etkileşimi

Uzaktan algılamada elektromanyetik ışınımın atmosfer ve yeryüzü ile etkileşimi önemli bir rol oynamaktadır. Yeryüzü açısından özellikle bitki örtüsü, toprak ve su, elektromanyetik enerji bakımından farklı dalga boylarında farklı yansıma karakteristiklerine sahiptir. Örneğin su yüzeyine gelen bir elektromanyetik enerji, yansılır, iletilir ya da emilir.



Şekil 1.5. Bitki örtüsü, toprak ve su için tipik yansıma eğrileri (Kumar 2019)

Şekil 1.5’te görüldüğü gibi sağlıklı bitki, kuru çıplak toprak ve temiz su gibi üç temel yeryüzü özelliği için tipik ortalama spektral yansıma eğrileri farklılık göstermektedir. Bu eğriler zaman zaman ortalamanın altında ya da üstünde değişiklikler gösterse de temel olarak kabul edilebilmektedir (Kumar 2019).

Elektromanyetik ışınımın yeryüzü nesnelere ile farklı etkileşimde bulunması, çalışma alanındaki arazi kullanımını ve arazi örtüsü bakımından sınıflar arası farklı spektral karakteristiklerin belirgin bir şekilde ortaya çıkmasına neden olmaktadır.

#### 1.4. Sayısal Görüntü İşleme

Üç boyutlu gerçek fiziksel bir sahnedeki nesnelere iki boyutlu gösterimine görüntü denir. Görüntüler, analog ve sayısal olmak üzere iki çeşittir. Analog görüntüler sayısal görüntülere dönüştürülürken örnekleme ve nicemleme işlemlerinden geçirilir. Önemli bir mekânsal bilgi kaynağı olan sayısal görüntüler genellikle binari, gri renk seviyeli, renkli ve çok spektrumlu olmak üzere dört çeşittir. Görüntüler üzerinden bir cismin ayırt edilebilirliği mekânsal, spektral ve radyometrik çözünürlüklerinin yanı sıra boyut, doku, kontrast ve örüntü gibi özelliklerle de ilişkilidir. Sayısal görüntülerin analizi genellikle, görüntülere ön işleme, zenginleştirme ve sınıflandırma işlem adımları uygulanarak gerçekleştirilmektedir (Sunar vd. 2013).

Tez çalışmasında aşağıdaki iş ve işlemler kullanılarak, öncelikle alana ait veriler analize hazır hale getirilmiştir. Daha sonra bu veriler sayısal görüntü analizi kapsamında sınıflandırma işlemine tabi tutulmuştur.

##### 1.4.1. Ön işleme

Ön işleme, uzaktan algılama yoluyla elde edilen verilerin sayısal analizi bağlamında, temel analiz için gerçekleştirilen ön işlemleri ifade etmektedir. Tipik bir ön işleme, atmosfer etkileri için sayısal değerleri ayarlamak amacıyla gerçekleştirilen radyometrik ön işleme ve bir görüntüyü harita veya başka bir görüntü ile kayda almak için geometrik ön işleme adımlarını içerebilmektedir. Bu aşama ile gerekli düzeltmeler yapıldıktan sonra veriler daha sonraki birincil analizlere tabi tutulabilir. Bu nedenle ön işleme, prensip olarak görüntüden bilgi elde edecek daha sonraki analizler için temel olarak görüntü kalitesini artıran bir hazırlık aşamasını oluşturmaktadır. Her ne kadar belirli ön işleme prosedürleri sıkça kullanılsa da, standart ön işleme adımlarının kesin bir listesi bulunmamaktadır. Ayrıca, görüntü verilerinin kalitesinin büyük ölçüde değişiklik göstermesi nedeniyle her proje bireysel olarak dikkat gerektirir ve bu kapsamda ön işleme uygulamaya karar verilebilirken bazı durumlarda buna gerek olmayabilir. Sonuç olarak, analistler, ön işleme ile sadece belirli bir sonuç elde etmek için gerekli olan işlemleri kullanarak elde edilen veriler ve belirli projelerin ihtiyaçlarına göre ön işleme uyarlamalıdır (Campbell and Wynne 2011).

Radyometrik ön işleme, sensör arızalarını düzeltmek veya atmosferik bozulmayı telafi etmek için bir görüntünün parlaklık değerleri üzerinde gerçekleştirilen işlemidir. Görünür veya yakın görülebilir radyasyon kullanarak Dünya'nın yüzeyini gözlemleyen herhangi bir sensör, iki tür parlaklığı kaydedecektir. Bunlardan ilki, Dünya yüzeyinden elde edilen parlaklık olup bu uzaktan algılama için önemli olan parlaklıktır. Ancak, algılayıcı ayrıca atmosferin kendisinin parlaklığını da gözlemler. Bu nedenle, gözlenen

bir sayısal parlaklık değeri, kısmen yüzey yansıtmasının sonucu ve kısmen de atmosferik saçılma sonucu olabilir. Kısacası, ön işlemenin amacı bu analizleri tanımlamak ve ayrımı yapabilmektir. Uzaktan algılanan görüntülerin çok büyük boyutları olabilmesi nedeniyle, göreve özgü tam görüntü bölümleri ile de çalışılabilmektedir. Bu nedenle ilk olarak, bilgisayar depolama alanını, zamanı ve harcanan çabayı en aza indirmek amacıyla her projede ilk olarak alt bölgeleri yani yalnızca ilgilenilen bölgeyi göstermek için seçilen daha büyük görüntülerin bölümleri hazırlanmalıdır. Uzaktan algılamada subset adı verilen bu altkümelerin seçilmesi işlemi en zorlu görevlerden biri olarak görülmesi de, ilk başta kullanıcılar açısından daha zor olabilmektedir. Genellikle görüntülerin kayıt edilmesinden önce alt kümeleri hazırlamak daha uygundur. Ancak alt küme çok küçükse, etkin kayıt için yeterli yer tanımlamak zor olabilir. Bu nedenle, analitik kullanım için daha küçük alt kümeyi seçmeden önce, görüntü kaydını etkili bir şekilde yürütecek kadar büyük bir ön alt kümenin hazırlanması yararlı olabilir. Alt kümeler, eldeki spesifik analiz için gereken bağlamı sağlayacak kadar büyük olmalıdır. Örneğin, görüntü sınıflandırma için yeterli sayıda eğitim alanı veya doğruluk değerlendirmesi için yeterli sayıda alan sağlamak için yeterince büyük alt kümeler hazırlamak önem arz etmektedir (Campbell and Wynne 2011).

Sayısal görüntülerde, farklı nedenlerle oluşabilecek geometrik distorsiyonlardan dolayı pikseller arasındaki mekânsal mesafelerde hatalar görülebilmektedir. Geometrik distorsiyon ile cisimlerin şekil, büyüklük ve konum gibi özellikleri görüntü düzleminde bozulmalara neden olmaktadır. Görüntülerde meydana gelen bu distorsiyonların bir projeksiyon sistemine göre düzeltilmesine rektifikasyon adı verilir. Rektifikasyon işlemi sonrasında piksellerin geometrik konumlarının yanı sıra radyometrik (parlaklık) değerleri de değişmektedir.

Görüntüdeki bu distorsiyonların tüm görüntüde eş zamanlı olarak giderilmesinde kullanılan iki yaklaşım bulunmaktadır. İlk yaklaşım sistematik bir yaklaşımdır ve distorsiyon düzeltmeleri ile distorsiyonun türü ve büyüklüğünün modellenmesi yapılarak hesaplanır. Söz konusu bu ilk yaklaşım, distorsiyonun tipi (uydunun konumsal durumu, tarama açısı, Dünya'nın dönüşü, bakış oranı, panoramik etki gibi) gibi etmenler iyi karakterize edildiğinde daha etkili olmaktadır. Distorsiyon giderilmesinde kullanılan ikinci yaklaşımda ise, distorsiyonlu verideki piksel koordinatları ile bunların arazideki karşılık geldiği koordinatlar arasında matematiksel bağlantı kurulur. Böylelikle, görüntüdeki distorsiyonun tipi ve kaynağı hakkında herhangi bir bilgiye gerek olmadan görüntü geometrisi düzeltilir. Sözü edilen bu ikinci yaklaşım, platformdan bağımsız ve en çok tercih edilen bir yaklaşımdır. Ayrıca söz konusu bu matematiksel ilişkilendirme yaklaşımı, birinci yaklaşımla birlikte hibrit olarak da kullanılabilir. Görüntülerdeki distorsiyonu düzeltme işlemlerinde, ilk yaklaşımla algılayıcı, uydu platformu ve yeryüzü kaynaklı distorsiyonlar düzeltildikten sonra geriye kalan artık distorsiyonlar ise ikinci yaklaşımla da düzeltilebilmektedir. Hangi yaklaşım kullanılırsa kullanılsın görüntülerin geometrik düzeltilmesinde genellikle, uygun matematiksel hata düzeltme modelinin seçimi, koordinat dönüşümü veya belirlenen modelin kullanımı ve parlaklık değerlerinin yeniden örneklenmesi aşamaları uygulanmaktadır (Sunar vd. 2013).

### 1.4.2. Görüntü zenginleştirme

Görüntü zenginleştirme en kısa ifadeyle, sayısal görüntülerin görsel görünümünü iyileştirme işlemidir. Uzaktan algılamada sayısal analizlerin artan önemi nedeniyle görüntü zenginleştirmenin önemi de artmaktadır. Her ne kadar sayısal analizlerin bazı yönleri geleneksel görüntü yorumlamasını azaltmış veya değiştirmiş gibi görünse de, bu prosedürlerin çoğu analistlerin görüntüleri incelemesine ve becerilerine dayanmaktadır. Görüntü zenginleştirme tekniklerinin bir görüntü için başarılı olanının başka bir görüntü için veya başka bir amaç için uygun olmayabileceği unutulmamalıdır. En çok kullanılan görüntü zenginleştirme teknikleri, kontrast zenginleştirme, doğrusal genişletme, histogram eşitleme, yoğunluklu dilimleme ve kenar zenginleştirmedir (Campbell and Wynne 2011).

### 1.4.3. Sınıflandırma

Uzaktan algılama teknolojileri kullanılarak elde edilen ham verilerden yeryüzü ile ilgili önemli bilgilerin elde edilebilmesi için daha çok tecrübeye dayanan görsel analiz ve yorumlamanın yanı sıra çeşitli istatistiksel analizlerden de yararlanılmaktadır. Bu maksatla uzaktan algılamada kullanılan en yaygın görüntü analiz yöntemi sınıflandırmadır. Görüntü sınıflandırma işleminin amacı, pikselleri arazi örtü sınıflarına göre gruplara ayırmaktır. Bu maksatla yapılan işlem sonucu benzer özellikteki pikseller yüzeyde temsilcisi olduğu varsayılan sınıflarla birlikte gruplandırılırlar (Lillesand vd. 2004).

Uzaktan algılama yoluyla elde edilen verilerin sınıflandırılmasında piksel tabanlı ve nesne tabanlı olmak üzere iki yöntem kullanılmaktadır. Bunlardan geleneksel bir yöntem olan piksel tabanlı sınıflandırma, kontrollü ve kontrolsüz olmak üzere iki şekilde uygulanabilmektedir. Kontrolsüz sınıflandırmada eğitim verisi diye ifade edilen örnek alanlar kullanılmazken, kontrollü sınıflandırmanın ilk aşamasında kullanıcı tarafından bu örnek alanlar belirlenmektedir. Bu aşama kontrollü sınıflandırmanın en önemli aşamasıdır. Örnek alanların kaliteli bir şekilde belirlenmesi sınıflandırmanın başarısını olumlu yönde etkilemektedir.

Son yıllarda görüntü analizi çalışmalarında özellikle nesne çıkarımına yönelik olarak nesne tabanlı sınıflandırma tekniği sıkça kullanılmaktadır. Bu sınıflandırma yöntemi kısaca görüntü bölütleme de diyebileceğimiz, piksellerin gruplandırılarak segmentler oluşturulması ve analizin bu segmentler üzerinden gerçekleştirilmesi esasına dayanmaktadır. Bu kapsamda piksellerin sadece spektral yansımaları değil, piksel grupları olan nesnelere doku, buldukları konum ve birbirleriyle olan bağlam bilgileri de kullanılmaktadır. Nesne tabanlı sınıflandırmanın en önemli adımı olan segmentasyon işleminde kullanılan farklı algoritmalar bulunmaktadır. Bu segmentasyon algoritmaları yardımı ile görüntüler diğer alanlardan daha küçük görüntü nesnelere bölünmektedir. Nesne tabanlı sınıflandırmada kullanılan en yaygın segmentasyon algoritması çoklu çözünürlüklü segmentasyon algoritmasıdır. Bu yöntem aşağıdan-yukarıya yaklaşımı ile küçük parçaların belirli kriterler göz önüne alınarak birleştirilmesi ve büyük parçaların elde edilmesi esasına dayanmaktadır (Trimble 2014).

Çoklu çözünürlüklü segmentasyon algoritması ile görüntünün segmentlere ayrılmasında ölçek parametresi ile şekil ve bütünlük kriterlerinin analist tarafından belirlenmesi gerekmektedir. Bunlardan en önemlisi olan ölçek parametresi, görüntüdeki

nesnelerin büyüklüğü ile ilgili olup verilen değer arttıkça daha büyük görüntü nesnelere elde edilmektedir. Ölçek değerinin daha küçük olması görüntüdeki nesnelerin daha küçük olması ve elde edilecek segment sayısının fazla olması anlamına gelmektedir.

Nesne tabanlı sınıflandırmada segmentasyon aşamasından sonra sınıflandırma aşaması gelmektedir. Görüntülerin sınıflandırılması amacıyla kullanılan klasik sınıflandırıcıların yanı sıra daha gelişmiş makine öğrenme algoritmaları da kullanılmaktadır. Bunlardan en klasik ve yaygın olanı, en yakın komşu (nearest neighbour) sınıflandırıcısıdır. En yakın komşu algoritması (K-NN), nesnelere özellik alanındaki en yakın eğitim örneklerine göre sınıflandırmaktadır. En yakın komşu sınıflandırıcısında bir nesne, komşu sayısına göre sınıflandırılırken, en yakın komşuları arasında en yaygın olan sınıfa atanır. Buradaki k sayısı, sınıflandırılmamış bir nesnenin ya da pikselin yakınında dikkate alınması gereken örnek sayısını ifade etmektedir (Trimble 2014).

Sınıflandırma işlemi sonrası gerçekleştirilecek doğruluk analizi oldukça önemlidir. Genellikle doğruluk analizi gerçekleştirilmeyen bir sınıflandırma işlemi tamamlanmış olarak kabul edilemez. Sınıflandırma doğruluğunun değerlendirilmesinde kullanılan en yaygın yöntemlerden birisi, hata matrislerinin oluşturulmasıdır. Bu matrisler, sınıflandırma işlemi sonucu belirlenen sınıfları yer gerçeği verileri ile karşılaştırmada kullanılan kare matrislerdir. Hata matrisi ile doğruluk değerlendirmesinde genel doğruluk, üretici doğruluğu ve kullanıcı doğruluğu olmak üzere üç tür doğruluk hesaplanır. Burada üretici doğruluğu, gerçekten ait olduğu sınıfa atanan görüntülerin referans veri içerisindeki oranı iken, kullanıcı doğruluğu ise bu görüntülerin gerçekten o sınıfa ait olma durumudur (Bayburt 2009).



## 2. KAYNAK TARAMASI

Dünya nüfusunun hızla artması ve buna bağlı olarak doğal kaynakların tükenmesi ile insan kaynaklı iklim değişikliklerinin olası sonuçlarına karşı başa çıkma yeteneğimiz, kısmen dünya sistemini ne kadar iyi anladığımıza ve bu bilgileri eylemlerimizi yönlendirmek için kullandığımıza bağlıdır. Uzaktan algılama teknolojisi, politika yapıcılar, kaynak yöneticileri, tahminciler ve diğer kullanıcılar tarafından ihtiyaç duyulan muazzam bir bilgi kaynağıdır. Bu kapsamda uzaktan algılama teknolojisinin kullanımı, dünyanın etkili ve sürdürülebilir gelecek yönetimi için giderek daha hayati bir hale gelmiştir. (Liang vd. 2012).

Uzaktan algılama uygulamalarında arazi örtüsü haritalaması, karar destek ve çevresel izleme sistemleri için zengin bir bilgi sağlamaktadır. Bu tür bilgilerin elde edilmesi, farklı kategorilerdeki karmaşık arazi örtüsü alanını belirlemek için sağlam sınıflandırma yöntemlerine olan güveni giderek daha fazla artırmaktadır. Uzaktan algılama görüntülerinin analizi için çok sayıda sınıflandırma tekniği tasarlanmıştır (Maulik and Chakraborty 2017).

Uzaktan algılama ile elde edilen verilerin analizinde etkili bir yöntem olan sınıflandırma işlemi ile yeryüzü hakkında detaylı bilgiler çıkarılabilmektedir. Son yıllarda bu maksatla kullanılan yüksek çözünürlüklü görüntülerde bir takım sorunların ortaya çıktığı görülmektedir. Bu problemlerin en önemlisi, yüksek çözünürlüğe bağlı olarak nesnelerin spektral yansımalarındaki benzerlik ve bu nedenle ortaya çıkan piksel karışıklığıdır. Bu karışıklık alandaki sınıfların hem kendi içerisinde hem de birbirleri arasında ciddi sınıflandırma problemlerine neden olabilmektedir. Bu nedenle ortaya çıkabilecek bu sorunların çözümüne yönelik olarak klasik analiz tekniklerinin yanı sıra farklı yöntemlerin uygulanması da gerekmektedir (Çölkesen 2015).

Uzaktan algılamada son yıllarda hava fotoğrafları ve yüksek çözünürlüklü uydu görüntülerinin temin edilmesinin kolay olması ve bu nedenle artan oranda kullanılması ile birlikte nesne çıkarımına yönelik çalışmalar önemli bir hale gelmiştir. Bu kapsamda klasik piksel-tabanlı metotlar, yüksek çözünürlüklü görüntülerdeki nesnelerin genellikle farklı spektral özniteliklere sahip heterojen piksellerden oluşması sebebiyle nesne çıkarımı aşamasında yetersiz kalmaktadırlar (Colkesen and Kavzoglu 2017).

Hamedianfar vd. (2015) çok yüksek çözünürlüklü uydulardan elde edilen, detaylı kentsel karakterizasyonu incelemek amacı ile yaptıkları nesne tabanlı görüntü analizi çalışmalarında, alandaki mekânsal ve spektral karakteristiklerin çeşitliliğinden dolayı iç kentsel özelliklerin otomatik olarak tespitinin zor olduğunu ifade etmişlerdir. Bununla birlikte WorldView-2 uydu görüntüsünden nesne tabanlı görüntü analizi kural setlerini oluşturularak, bu setin transfer edilebileceğini ifade etmişlerdir. Ayrıca araştırmacılar, sınıflandırma doğruluğunun artırılmasında, alana ait kaç spektral indeksin, mekânsal, spektral ve yapısal özelliklerin de bu kural setlerinde birleştirilebileceğini belirtmişlerdir.

Kalkan (2011) kentsel gelişim için potansiyel açık alanların belirlenmesinde nesne tabanlı sınıflandırma yöntemi ile transfer edilebilir kural dizisi oluşturulması çalışmasında arazi örtüsü ve kullanımı özelliklerinin belirlenmesi için piksel tabanlı sınıflandırma yöntemine göre avantajlı olan nesne tabanlı sınıflandırma yöntemi tercih

etmiştir. Çalışmada Quickbird uydu görüntüsü, ön işleme adımında yazılım olarak Erdas, nesne tabanlı sınıflandırmada ise eCognition kullanılmıştır. Yürütülen araştırmada, nesne tabanlı sınıflandırmanın en önemli kısmı olan segmentasyon aşamasında kullanılacak parametre ve veri setlerinin yapılan testler sonucunda belirlendiği ve böylelikle nesnelere yanlış oluşturulmasının engellendiği ifade edilmiştir. Çalışmada ayrıca, kural dizisinin transfer edilebilir hale getirilmesi amacı ile işlem adımları esnek bir şekilde geliştirilmiş ve değişik bölgelere göre kullanıcının müdahale edebileceği kısımlar eklenmiştir.

Li vd. (2014) hava fotoğraflarını kullanarak nesne tabanlı arazi örtüsü sınıflandırması yapmışlardır. Çalışmada, ayrıntılı arazi örtüsü sınıflandırması için nesne tabanlı bir yaklaşım ile birlikte hava fotoğraflarının yanı sıra kadastral CBS vektör katmanı da yardımcı veri olarak kullanılmıştır. Segmentasyon ve sınıflandırma işlemleri sonucunda, elde edilen arazi örtüsünün 12 sınıf ve alt sınıf içerdiği tespit edilmiştir. Araştırmacılar, çalışmada önerilen nesne tabanlı sınıflandırma yöntemi sonuçlarının iyi olduğunu ve mevcut yardımcı verilerin kullanılmasının hesaplama süresini azalttığını belirtmişlerdir.

Aguilar vd. (2014) yüksek çözünürlüklü uydu görüntülerinden nesne tabanlı sera sınıflandırması yaptıkları çalışmayı, temel spektral bilgi, yükseklik verileri, indeksler, doku ve şekil geometrisi gibi farklı özellikleri de kullanarak gerçekleştirmişlerdir. Çalışma sonucunda yüksek çözünürlüklü GeoEye-1 ve WorldView-2 uydu görüntülerinden seraların belirlenmesinde en iyi genel doğruluk değerini % 90'a yakın tespit etmişlerdir.

Aguilar vd. (2015) tarafından yapılan bir başka çalışmada ise, serada yetişen bitkilerde ürün tanımlanması gerçekleştirilmiştir. Bu amaçla, nesne tabanlı görüntü analizi kullanılmıştır. Landsat 8 ve WorldView-2 uydu verilerinden türetilmiş temel spektral bilgi, dokusal özellikler ve birkaç bitki indeksi daha önce bölünmüş görüntü nesnelere üzerinde sınıflandırılmıştır. En iyi sınıflandırma genel doğruluğu % 81.3 Landsat 8 serisinin tüm setini kullanarak elde edilmiştir. Bu sonuçlar, domates ve biber mahsullerinde iyi, salatalık ve patlıcan için önemli ölçüde kötü olarak bulunmuştur. Araştırmada elde edilen bu sonuçların değişmesinde, WorldView-2 görüntüsü bilgisinin eklenmesinin yeterli olmadığı da ortaya konmuştur. Çalışma sonucunda, seralar altındaki farklı ürünlerin doğru sınıflandırılmasında en önemli bilginin, bitkilerin kendi spektral özellikleriyle değil sera yönetimi uygulamalarıyla ilgili olduğu belirlenmiştir.

Marangoz (2009) uydu görüntüleri kullanarak obje tabanlı sınıflandırma ile kent alanındaki detayların belirlenmesi ve elde edilen sonuçların CBS ile entegrasyonu çalışmasında, günümüzde yüksek çözünürlüklü uydu görüntülerinin neden yoğun olarak kullanılmaya başlandığı ve bu görüntülerden mekânsal bilgi elde etmede etken olan verinin bilgi içeriği kavramını örnekler vererek incelemiştir. Uygulama sonunda, gölgede kalmayan, açık alanlardaki ana yolların ve düzgün yerleşim alanlarındaki tali yolların obje tabanlı yöntem kullanarak iyi bir şekilde çıkarılabileceği belirlenmiştir. Ayrıca araştırmacı bazı yollar ile boş arazilerin spektral karışmaya neden olması neticesinde bu yöntemin, bazı yol yapılarının çıkarımında başarısız olduğunu belirlemiştir. Araştırmacı genel anlamda iyi bir sınıflandırma sonucu elde edebilmek için, uygulama yapılacak bölgenin 1m'den daha az yer örneklem mesafesi değerine sahip uydu görüntüsüne ihtiyaç duyulduğunu belirtmiştir. Bu bağlamda çalışmada, gelişen teknolojiyle birlikte

WorldView ve GeoEye gibi uydu sistemlerinin görüntülerinin kullanılması önerilmiştir.

Karlson vd. (2014) tarafından yarı-kurak Batı Afrika'nın yönetilen ormanlık alanlarında ağaç taç haritalaması gerçekleştirilmiştir. Çalışmada WorldView-2 uydu görüntülerini ve nesne tabanlı görüntü analizini kullanmışlardır. Elde edilen bulgular referans veriler ile değerlendirildiğinde genel doğruluk % 85.4 olarak belirlenirken yüksek ağaç yoğunluğuna ve yoğun bitki örtüsüne sahip bölgelerde daha düşük doğruluk değeri tespit edilmiştir.

Peña-Barragán vd. (2011) çoklu vejetasyon indeksleri, dokusal özellikler ve ürün fenolojisini kullanarak nesne tabanlı ürün tanımlama çalışmalarında, üç ayrı büyüme mevsiminde elde edilen ASTER uydusunun görünür, kızılötesi ve kısa dalga kızılötesi bandlarından üretilmiş bitki örtüsü indeksi ve dokusal özellikleri kullanmışlardır. Çalışma sonucunda NDVI, tarlalardaki yeşil bitki örtüsünün varlığına ve canlılığına bağlı olarak ana ürün gruplarını tanımlamak için kullanılmış ve NDVI'nin modellere yaklaşık % 50 katkıda bulunduğu belirlenmiştir. Araştırmacılar, SWIR bandlarına dayanan diğer bitki örtüsü indekslerinin de nem, bitki örtüsü canlılığı, fotosentetik olmayan bitki örtüsü ve çıplak toprak gibi alan özelliklerini tespit etme potansiyelleri nedeniyle ürün tespitinde oldukça önemli olduğunu ifade etmişlerdir.

Puissant vd. (2014) kentsel ağaç alanlarını nesne tabanlı yaklaşımla birlikte random forest sınıflandırıcısı kullanarak çok yüksek çözünürlüklü bir optik görüntüden haritalamak ve bir metodoloji önermek amacıyla yürüttükleri çalışmayı Strasbourg şehrinin farklı alanlardaki farklı yerleşim kategorilerinden oluşan bir veri seti üzerinde değerlendirilmişlerdir. Araştırma sonuçlarına göre, random forest sınıflandırıcısı kullanarak kentsel ağaçların nesne tabanlı haritalanmasında kullanıcı ve üretici doğrulukları açısından yeşil örtünün sınıflandırılması için iyi bir doğruluk ve yüksek sağlamlık olduğunu belirlenmiştir.

Balçık (2018) tarafından Sentinel 2 verilerinin farklı bitki indeksleri kullanarak arazi kullanımı ve sınıflandırması için değerlendirildiği çalışmada alanda su yüzeyleri, orman alanları, farklı tarım alanları, açık maden alanı, yerleşim yerleri ve yol gibi farklı örtü tipleri ve arazi kullanımı belirlenmiştir. Çalışma için belirlenen dört farklı veri seti en yüksek olabilirlik sınıflaması yöntemiyle analiz edilmiştir.

Strasser ve Lang (2015) nehir kenarı orman habitat haritalaması için çoklu ölçekli nesne tabanlı sınıf modellemesi çalışmalarını, Avrupa Doğa Bilgi Sistemi habitat sınıflandırmalarına ve Avrupa Habitat Direktiflerine göre gerçekleştirmişlerdir. Bu kapsamda habitatların sınıflandırma modelini uygulayarak nehir kıyısı ormanlarının haritalanması için yarı otomatik nesne tabanlı görüntü analizi yaklaşımını sunmuşlardır. Çalışmada çok yüksek çözünürlüklü WorldView-2 uydu görüntüsü ile orman habitatlarının altı seviyeli bir hiyerarşik sunumunu oluşturmak için çoklu ölçekli bir görüntü segmentasyonu kullanılmıştır.

Marangoz vd. (2013) Sakarya'nın Karasu ilçesinde kıyı şeridinin Landsat görüntüleri ve nesne tabanlı sınıflandırma yöntemi ile zamansal analizini gerçekleştirmişlerdir. Bu amaçla çalışmada dört farklı yıla ait Landsat 5 ve Landsat 7 uydu görüntüleri kullanılmıştır. Bu görüntüler, eCognition yazılımı ile segmentasyon ve

sınıflandırma aşamalarına tabi tutulmuştur. Ayrıca bu sonuçlar manuel sayısallaştırma yoluyla elde edilen referans veriler ile karşılaştırılarak doğruluk analizleri gerçekleştirilmiştir. Çalışma sonucunda 2006 ve 2010 Landsat görüntülerinde nesne-tabanlı sınıflandırma yaklaşımı ile kıyı erozyonunun belirlenemediği, diğer görüntülerde ise karşılaştırılan yöntemlerin benzer neticeler verdiği belirlenmiştir. Buna göre araştırmacılar tarafından, benzer araştırmalarda yüksek çözünürlüklü görüntülerin kullanılması ile zamansal analizin başarı ile gerçekleştirilebileceği değerlendirilmiştir.

Novelli vd. (2016) Sentinel-2 ve Landsat 8 verilerini kullanarak nesne tabanlı sınıflandırma yöntemi ile seraların tespit edilmesinde performans değerlendirmesi yapmışlardır. Bu çalışmada alan her algılayıcı için nesne tabanlı görüntü analizi ve random forest kullanılarak sınıflandırılmıştır. Tüm çalışma alanı boyunca sırasıyla en iyi genel doğruluk değerleri, % 89.1, % 91.3, % 90.9 ve % 93.4 olarak bulunmuştur.

Çömert vd. (2016) nesne tabanlı bina çıkarımı için İHA verilerinden üretilen 6 cm mekânsal çözünürlüğe sahip ortofoto görüntü ve sayısal yükseklik modelini kullanmışlardır. Bina çıkarımı işlemi bu verileri kullanarak nesne tabanlı yarı otomatik olarak gerçekleştirilmiştir. Bu amaçla oluşturulan kural setlerinde sayısal yükseklik modelinden elde edilen yükseklik ve ortofoto görüntünün spektral bantları kullanılmıştır. Çalışma sonucunda alanda yer alan binalardan 37'sinin 34'ü çıkarılmıştır.

Lim vd. (2015) segmentasyon işlemi ile ağaç yüksekliği ve kanopi tacının hesaplanmasına yönelik yaptıkları çalışmalarında, havadan LIDAR'a göre daha uygun maliyetli ve kontrol edilebilir olan drone görüntüsü kullanmışlardır. Bu kapsamda farklı test alanlarına göre iki yüksek çözünürlüklü sayısal yüzey modeli üretilmiş ve segmentasyon işlemi ile ağaç tanımlaması yapılmıştır. Belirlenen ağaçların yükseklik ve kanopi genişlikleri hesaplanarak referans verilerle karşılaştırılmıştır.

Özcan (2017) tarafından yürütülen İHA kullanarak farklı yüksekliklerden elde edilen SYM'lerin doğruluklarının değerlendirilmesi çalışmasında, İHA ile farklı yüksekliklerden yapılan uçuş görevlerinde sayısal kameradan alınan görüntülerin ve üretilen SYM'lerin mekânsal doğruluklarının ortaya konulmasını amaçlamıştır. Bu kapsamda, yer kontrol noktalarının koordinatları GPS ile alınarak mekânsal doğrulama için kullanılmış, üretilen nokta bulutlarının doğrulukları arazi ölçmeleri ile karşılaştırılmış ve düşeyde İHA ve GPS ile yapılan ölçümlerde ortalama olarak cm seviyesinde farklar elde edilmiştir. Çalışmada yüzey topoğrafyasında ani değişimlerin olduğu bölgelerde ise farkın arttığı gözlenmiştir.

Qin (2014) farklı zamanlarda alınan İHA görüntülerinden gelen değişimleri saptamak amacı ile nesne tabanlı hiyerarşik bir yöntemi önerdiği çalışmasında, oktokopter ile farklı tarihlerde görüntüler elde etmiştir. Çalışmada bu görüntülerde, ölçek-değişken özellik dönüşümü özellik noktalarına göre otomatik olarak kaydedilerek raster tabanlı değişim analizi için sayısal yüzey modelleri ve ortofoto oluşturulması sağlanmıştır. Daha sonra, nesne tabanlı analiz için segmentasyon işlemi ve son olarak da değişim ölçümü için yükseklik, spektral, geometrik tutarlılık ve şekil düzenliliği ile ilgili çok kriterli bir karar analizi gerçekleştirilmiştir. Araştırmacı, mekânsal çözünürlüğü 5 cm olan İHA görüntülerine dayanan denemelerin, önerilen yöntemin etkililiğini ortaya koyduğunu ve bu yöntemin sık izleme açısından pratik olarak uygulanabilir olduğunu

belirtmiştir.

Kalantar vd. (2017) nesne tabanlı görüntü analizine bütünleşmiş bir algoritma kullanarak drone tabanlı arazi örtüsünün haritalanması işlemini, FURIA algoritması kullanarak gerçekleştirmişlerdir. Çalışmada, İHA kullanılarak çekilen görüntüler çoklu çözünürlüklü segmentasyon algoritması kullanarak bölütlenmiş ve bu veirlerde sınıflandırma işlemi gerçekleştirilmiştir. Önerilen yaklaşımın sonuçları karar ağacı (DT) kuralları ve Destek Vektör Makinesi (SVM) sınıflandırma yöntemiyle karşılaştırılmıştır. Araştırma sonuçlarına göre önerilen yöntemin DT ve SVM'den genel olarak % 91.23 ile daha iyi performans gösterdiği belirlenmiştir. Araştırmacılar, çalışmadan elde edilen bulanık kuralların, İHA görüntülerinden arazi örtüsü çıkarmada geleneksel kurallara göre daha uygun olduğunu önermişlerdir.

Selim vd. (2019) ağaçları belirlemek amacıyla İHA görüntüleri ve nesne tabanlı sınıflandırma yöntemi kullanarak gerçekleştirdikleri çalışmalarında 30 m yükseklikten alınan hava fotoğraflarını kullanmışlardır. Yürütülen çalışma kapsamında elde edilen hava fotoğrafları mozaikleme işlemi ile birleştirilerek jeorefeanslama ve filtreleme işlemleri gerçekleştirilmiştir. Çalışmada görüntü analizi olarak nesne tabanlı sınıflandırma yöntemi tercih edilmiştir. Bu kapsamda görüntüler üzerinden ağaç ve diğer sınıfları oluşturulmuş ve ağaç yüksekliklerinin belirlenmesinde sayısal yüzey modelinden de yararlanılmıştır. Araştırmacılar sınıflandırma işlemi sonucu belirlenen ağaç sayıları ve taç genişliklerini alandaki yer gerçeği verileri ile karşılaştırdıklarında sonuçların tutarlı olduğunu tespit etmişlerdir.

Chhetri vd. (2017) tarafından çok yüksek çözünürlüklü İHA görüntülerini kullanarak yürütülen bir çalışmada, sulak alan bitki örtüsünün obje tabanlı sınıflandırılması amaçlanmış ve bu amaçla, çoklu çözünürlüklü obje tabanlı sınıflandırma yöntemlerinin kullanımını incelemek ve performansını piksel tabanlı sınıflandırma yöntemi ile karşılaştırmak hedeflenmiştir. Çalışmada destek vektör makinesi, yapay sinir ağı ve en yüksek olabilirlik olmak üzere üç tür sınıflandırıcı kullanılmıştır. Araştırmada nesne tabanlı sınıflandırmanın, aynı tip sınıflandırıcı kullanıldığında piksel tabanlı sınıflandırmalardan daha yüksek doğruluk sağladığı tespit edilmiştir. Çalışma sonucunda, sınıflandırma performansını iyileştirmek için görüntü kalitesiyle ilgili bazı konuların ele alınması gerektiği sonucuna varılmıştır.

Nonni vd. (2018) Sentinel 2 ve İHA multispektral görüntülerinin karşılatılmasına yönelik gerçekleştirdikleri bir çalışmada, hassas bağcılık için bağların mekânsal ve zamansal değişkenliğini tespit edebilen teknolojilerin kullanılmasını ve aynı zamanda sürdürülebilir maliyetlerle faydalı bilgilerin elde edilmesinin sağlanabileceğini belirtmişlerdir. Yapılan çalışmada, Sentinel 2 ve İHA görüntülerinden elde edilen normalize bitki örtüsü fark indeksi yardımıyla her iki verinin nitel ve istatistiksel açıdan değerlendirilmesi amaçlanmıştır. Elde edilen sonuçlara göre, bağların izlenmesi ve bitkisel üretim için kritik alanların belirlenmesi amacıyla açık kaynaklı Sentinel-2 platformlarının potansiyel kullanımını başarılı bir şekilde ortaya koyulduğu ifade edilmiştir.

Kalkan ve Maktav (2010) İkonos uydu verilerinde nesne tabanlı ve piksel tabanlı sınıflandırma yöntemleri karşılaştırmışlardır. Çalışma sonucunda nesne tabanlı

sınıflandırma yönteminin tematik sınıf için iyi sonuçlar verdiği belirtilmiştir. Çalışmada, eCognition yazılımı ve en yakın komşu sınıflandırıcısı kullanılmıştır. Çalışma sırasında pek çok parametre, segmentasyon aşaması için farklı ölçekler, farklı segmentasyon aşamaları ve en yakın komşu sınıflandırma algoritması test edilmiştir. Araştırmacılara göre yapılan analizler sonrasında, nesne tabanlı yaklaşım pek çok sınıf için daha iyi sonuçlar vermiştir.

Duro vd. (2012) SPOT-5 uydu görüntüsü kullanarak tarımsal alanların sınıflandırılması amacı ile seçilen makine öğrenme algoritmalarıyla piksel tabanlı ve nesne tabanlı görüntü analizlerinin karşılaştırılmasına yönelik bir çalışma yürütmüşlerdir. Bu amaçla sınıflandırma işlemi piksel tabanlı ve nesne tabanlı görüntü analizi yöntemleri makine öğrenme algoritmalarından decision tree, random forest ve support vector machine kullanılarak gerçekleştirilmiştir. Çalışma sonucunda aynı makine öğrenme algoritmaları uygulandığında, piksel tabanlı ve nesne tabanlı sınıflandırmalar arasındaki genel sınıflandırma doğruluklarının istatistiksel olarak anlamlı olmadığı tespit edilmiştir. Araştırmacılar, nesne tabanlı görüntü analizinde, random forest veya support vector machine algoritmaları kullanılarak üretilen haritalarla karşılaştırıldığında, decision tree algoritması ile üretilen haritalar arasında sınıflandırma doğruluğunda istatistiksel olarak önemli bir fark olduğunu, piksel tabanlı görüntü analizini kullanarak gerçekleştirilen sınıflandırma doğruluklarında ise istatistiksel olarak anlamlı bir fark olmadığını belirlemişlerdir.

Kalem (2014) piksel ve nesne tabanlı sınıflandırma yöntemlerini karşılaştırmada Göktürk 2 uydu görüntüsü kullanırken bu verinin yanı sıra İstanbul şehrine ait SPOT 5 ve LANDSAT 8 uydu görüntülerini de kullanarak piksel ve nesne tabanlı sınıflandırma yapmıştır. Çalışmada piksel tabanlı kontrolsüz sınıflandırma yapılırken ISODATA yöntemi, piksel tabanlı kontrollü sınıflandırma yapılırken en yüksek olabilirlik yöntemi kullanılmış ve doğruluk analizi yöntemiyle elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Araştırmada, nesne tabanlı sınıflandırma işlemleri için öncelikli olarak görüntülere uygun segmentasyon parametreleri belirlenmiş ve sonrasında sınıflara özel karar ağaçları oluşturularak nesne tabanlı sınıflandırma işlemi yapılarak elde edilen doğruluk analizleri karşılaştırmalı değerlendirilmiştir.

Rastner vd. (2014) optik uydu görüntülerinden zorlu haritalama koşullarına sahip üç test bölgesinde buzul haritalaması için nesne tabanlı ve piksel tabanlı yöntemlerin performansını karşılaştırmışlardır. Her iki yaklaşımda da, temiz karı ve buz haritalamak için bir oran görüntüsü oluşturulmuş, yıkıntılarla kaplı buzun tanımlanmasına yardımcı olmak için termal ve eğim bilgileri kullanılmıştır. Çalışma sonucunda nesne tabanlı haritalamanın piksel tabanlıya göre % 3 daha yüksek doğruluğa sahip olduğu belirlenmiştir. Özellikle yıkıntılarla kaplı buzullarda bu oranın % 12, nesne tabanlı haritalama lehine olduğu tespit edilmiştir.

Jumaat vd. (2018) tarafından yüksek çözünürlüklü uydu ve İHA verileri kullanarak arazi örtüsü değişiminin haritalanması çalışmalarında, IKONOS, Quickbird ve İHA verilerini kullanmışlardır. Sınıflandırma işlemi sonuçlarına göre, İHA için % 93.80, IKONOS için % 86.67 ve QuickBird için ise % 83.89 genel doğruluk değerleri elde edilmiştir.

Weih ve Riggan (2010) tarafından piksel tabanlı kontrollü ve kontrolsüz sınıflandırmayla nesne tabanlı sınıflandırmanın karşılaştırıldığı çalışmada, yapraklı ve yapraksız olmak üzere iki farklı zamanlı, orta mekânsal çözünürlüğe sahip olan SPOT-5 uydu görüntüleri ile yüksek mekânsal çözünürlüklü renkli kızılötesi sayısal ortofoto kullanılmıştır. Çalışmada, bu üç görüntü kombinasyonu, çok zamanlı ve çoklu mekânsal görüntülerin sınıflandırma doğruluğuna göreceli önemini değerlendirmek için birleştirilmiştir. Araştırma sonucunda, üç görüntü veri setinin tamamını kullanan nesne tabanlı sınıflandırma % 82.0 ile en yüksek genel doğruluğa ulaşılmış iken, SPOT-5 yapraksız görüntüyle birleştirilmiş yüksek mekânsal çözünürlüklü görüntüyü kullanan nesne tabanlı sınıflandırmanın genel doğruluğu % 78.2 olarak bulunmuştur. Araştırmacılar, iki nesne tabanlı sınıflandırmanın birbirinden önemli ölçüde farklı olmasa da, diğer sınıflamalardan istatistiksel olarak önemli derecede farklı olduğunu, özellikle nesne tabanlı sınıflandırmalarda yüksek mekânsal çözünürlüğe sahip görüntülerin varlığının, çok zamanlı veri setine göre genel doğruluğun geliştirilmesinde daha büyük bir etkiye sahip olduğunu ifade etmişlerdir.

Meneguzzo vd. (2012) tarafından yapılan bir çalışmada, ağaç örtüsünü haritalamak amacı ile yüksek çözünürlüklü görüntüler kullanılarak iki uzaktan algılama tabanlı yaklaşım denemiştir. Bu amaçla, kontrolsüz piksel tabanlı sınıflandırma (independent component analysis-ICA) ve nesne tabanlı görüntü analizi kullanılmış ve elde edilen sonuçlar birbirleri ile karşılaştırılmıştır. Araştırmada, her iki yaklaşımın da, ağaç örtüsünün geniş bir mekansal çerçevede haritalandırılması için uygun olduğu ve zemine dayalı envanter verilerini tamamlamak için yararlı olabileceği bulunmuştur. Çalışma sonuçlarına göre ICA yaklaşımı, toplam ağaç örtüsünün fotoğraf ile yorumlanmasından daha iyi bir sonuç vermiş ancak nesne tabanlı görüntü analizi yöntemi ile elde edilen çıktının daha gerçekçi olduğu tespit edilmiştir.

Adam vd. (2016) piksel tabanlı ve nesne tabanlı sınıflandırma yaklaşımlarının karşılaştırıldığı çalışmayı Sudan'ın yarı kurak bölgelerinde arazi örtüsünü sınıflandırmak amacı ile gerçekleştirmişlerdir. Çalışmada hem yöntemlerin karşılaştırılması hem de her yöntem için sınıflandırma doğruluklarının belirlenmesi amaçlanmıştır. Çalışma sonucunda elde edilen piksel tabanlı ve nesne tabanlı sınıflandırmanın ürettiği genel doğruluk ve Kappa istatistiği sırasıyla (% 72.92 ve % 54.17) ve (0.63 ve 0.38) olarak bulunmuştur.

Elhag ve Boteva (2016) arazi kullanımı/arazi örtüsü haritalamasında en iyi sınıflandırma performansını belirlemek amacıyla gerçekleştirdikleri çalışmada, yüksek mekânsal çözünürlüklü Sentinel-2 uydusunu kullanmışlardır. Yürütülen bu çalışma ile hem piksel tabanlı hem de nesne tabanlı bir sınıflandırma algoritması değerlendirilmiştir. Araştırmacılar, piksel tabanlı yaklaşımda en yüksek olabilirlik, yapay sinir ağı algoritmaları, destek vektör makinesi ve nesne tabanlı sınıflandırmada ise en yakın komşu sınıflandırıcısını kullanmışlardır. Sınıflandırma sonuçlarına uygulanan doğruluk analizi neticesinde, dört yöntemin hepsinin de sınıfların çoğunu en yüksek doğrulukla ayırt edebildiği SVM sınıflandırıcısının ise en verimli olduğu ortaya konmuştur. En yakın komşu sınıflandırıcısı genel olarak suni yüzey sınıflarında başarılı iken, tarım alanı, orman ve yarı-doğal alan sınıflarında SVM daha başarılı bulunmuştur.

Zoleikani vd. (2017) piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerinin

karşılaştırılmasını hiperspektral pansharpened görüntüler ile kentsel alanda arazi örtüsü haritalaması üzerinden gerçekleştirmişlerdir. Araştırmada, sınıflandırmada yararlı olduğu düşünüldüğünden farklı görüntü füzyon yöntemleri kullanılmıştır. Her iki yaklaşımın değerlendirildiği sınıflandırma sonuçlarına göre (% 90.47 ve % 77.33) nesne tabanlı sınıflandırma piksel tabanlıya göre daha doğru sonuçlar verdiği ifade edilmiştir.

Başayığıt ve Ersan (2015) tarafından bitki desen ayırımında piksel ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması çalışması gerçekleştirilmiştir. Araştırmacılar çalışmada veri olarak Quickbird-2 uydu görüntüsü, yazılım olarak ise ERDAS ve eCognition'ı kullanmışlardır. Yürütülen bu araştırmada Quickbird-2 uydu görüntüsünün piksel tabanlı sınıflandırılmasında, kontrollü sınıflandırma için en yüksek olabilirlik, kontrolsüz sınıflandırma için ISODATA algoritmaları ve nesne tabanlı sınıflandırma için ise çoklu çözünürlüklü segmentasyon algoritması kullanılmıştır. Çalışma sonuçlarına göre araştırmacılar tarafından nesne tabanlı sınıflandırma yönteminin, piksel tabanlı sınıflandırma yöntemine göre daha başarılı olduğu belirlenmiştir.

Zabala (2017) tarafından ürün tipinin haritalanmasına yönelik olarak Sentinel 2 ve İHA görüntülerinin değerlendirildiği çalışma farklı bitki indeksleri kullanılarak gerçekleştirilmiştir. Araştırmacı, İHA'dan elde edilen ortomozaikten türetilen NDVI verisini, zaman serisini tamamlamak ve zamansal değişimi ne kadar iyi temsil ettiğini değerlendirmek amacı ile kullanmıştır. Çalışma sonucunda Sentinel 2 NDVI zaman serisinin bitki izlemesi dâhil olmak üzere çeşitli tarım uygulamaları için yüksek değerde mevsimsel bilgi sağlama potansiyeline sahip olduğu belirlenmiştir.

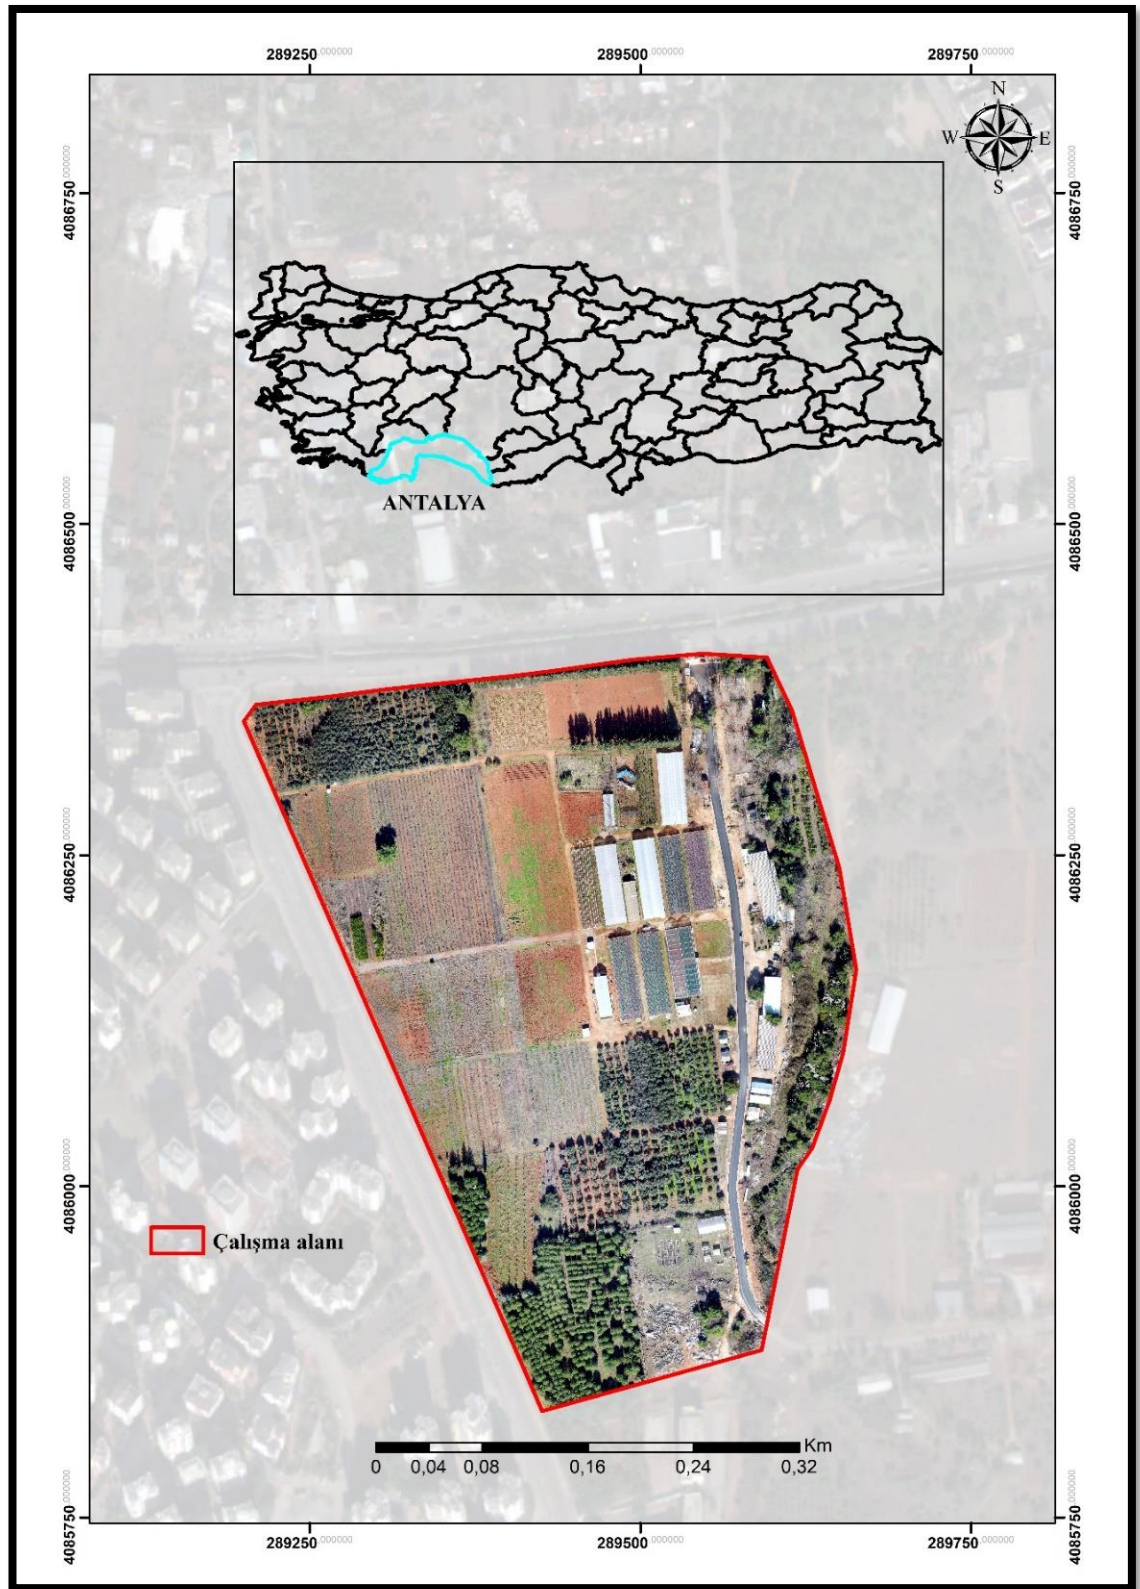


### 3. MATERYAL VE METOT

#### 3.1. alıřma Alanı

Bu alıřma Antalya ili Konyaaltı ile sınırlarında yer alan Akdeniz niversitesi merkez yerleřke arazisinde 36°53'59" Kuzey enlemleri ile 30°38'25" Doęu boylamları arasında yrtlmřtr (řekil 3.1). Konyaaltı ilesi, Antalya ilinin batı ucunda yer almaktadır. Turizm aısından deęerlendirildięinde plajlarıyla nl olmasına raęmen aynı zamanda ekilebilir arazilerin yarısında sulu tarım da yapılmaktadır. İlede toplam 57.633 dekar alandaki tarım arazisinin 37.579 dekarlık blmnde tarım yapılmaktadır. Aęırlıklı olarak rtaltı sebze yetiřtiricilięi, nar ve narenciye retilmektedir. 2.031 dekar alanda da buęday ve arpa yetiřtirilmektedir. İlede ayrıca 2.995 dekarlık alanda seracılık, 23.209 dekar alanda ise meyvecilik yapılmaktadır (Anonim 1).

Gerek ekonomik gerek kltrel bakımdan nemli bir yere sahip olan Akdeniz niversitesi yerleřkesinin burada bulunması, ulusal ve uluslararası alanda Konyaaltı ilesinin tanınırlıęına katkı saęlamaktadır. Akdeniz niversitesi merkez yerleřkesi, idari ve akademik birimlerin yanı sıra yeřil alan bakımından da olduka zengindir. Bu alanın yoęunlukta olduęu ve aynı zamanda yerleřkenin kuzeybatısında yer alan ve 17.38 hektarlık bir alana sahip blgede ok yıllık tarımsal retim alanları, tek yıllık tarımsal retim alanları, orman alanları, sera ve yerleřim alanları mevcuttur. Bu blgede Ziraat Fakltesi arařtırma ve uygulama alanları ile deneme parsellerinin bulunması nedeniyle ok farklı bitkiler bulunmaktadır. alıřma alanının seiminde yukarıda belirtilen zellikler etkili olmuřtur.



Şekil 3.1. Çalışma alanı

### 3.2. alıřmada Kullanılan Veriler

alıřmada kullanılan temel veriler, İHA'ya monte edilmiř kameralardan elde edilen gncel yksek znrlkl ortomozaik grntler, yksek znrlkl uydu verileri ile alıřma alanına ait yazılı ve grsel dokmanlardır. alıřmada, İHA'ya monte edilen yakın kızıltesi, kırmızı ve grnr blgeyi ayrı ayrı algılama yetisine sahip olan kameralar vasıtası ile farklı dalga boyu aralıęında yksek znrlkl veriler kullanılmıřtır.

alıřmanın n iřleme ve grnt zenginleřtirme ařamalarında Erdas ve ArcGIS yazılımlarından yararlanılmıřtır. Ayrıca İHA'dan elde edilen verilerden ortomozaik grnt ve sayısal yzey modeli retilmesi iřlemleri Agisoft ve Pix4D yazılımları, sınıflandırma ve doęruluk analizi iřlemleri ise Erdas, ArcGIS ve nesne tabanlı sınıflandırmada sıklıkla kullanılan eCognition yazılımı ile yapılmıřtır. Bu alıřmada iki farklı temel veri kullanılmıřtır. Bunlardan ilki Őekil 3.2'de grlen İHA ile elde edilen verilerdir.



a)



b)



c)

Őekil 3.2. alıřmada kullanılan a) İHA; b) RGB kamera; c) RGN kamera

Inspire 2 İHA'sı yaklaşık 23-27 dakika uçuş süresine, gimbal ve kamera olmadan pervaneler ve iki pil dâhil 3440 gr. ağırlığa sahiptir. Bu ağırlık kalkış için maksimum 4250 gr. olabilmektedir (Anonymous 1). Çalışmada kullanılan ve RGB görüntü sağlayan ve İHA'ya monte edilebilen kamera, Zennuse X4S olup 253 gr ağırlığındadır. Zennuse X4S kamerada CMOS, 1" Effective Pixels: 20 MP sensör bulunmaktadır. Kullanılan bu kameraya ait diğer bazı temel özellikler çizelge 3.1'de görüldüğü gibidir.

**Çizelge 3.1.** Zennuse X4S kameranın özellikleri (Anonymous 2)

Görüş Alanı	Fotoğraf Çözünürlüğü	Lens	Fotoğraf Formatı	Açısal Titreşim Aralığı
84°	3:2, 5472×3648 4:3, 4864×3648 16:9, 5472×3078	F/2.8-11, 8.8mm (35 mm Equivalent: 24mm)	DNG, JPEG, DNG+JPEG	±0.01°

Inspire 2 İHA'sına monte edilebilen ve teknik özellikleri şekil 3.2'de verilen Survey 3, bu kapsamda üretilen en yeni kameralardandır. Survey 3 kamera, yakalanan her bir görüntüyü otomatik olarak coğrafi etiketlemek için harici bir GPS alıcısı içerir. 12 MP sensörü ve keskin balıkgözü olmayan lensi, havadan kolayca çekim işlemi sağlar. Bu Kırmızı+Yeşil+NIR (RGN, NDVI) modelinde Yakın Kızılötesi 850nm, Kırmızı 660nm ve Yeşil 550nm spektral yansıma değerlerine sahiptir. Bu kameradan gelen görüntüler, genellikle bir indeks görüntüsüne kalibre edilerek daha sonra sağlıklı ve sağlıklı bitki örtüsü arasındaki kontrastı göstermek için uygulanır. Survey 3 kameraları daha hızlı bir zamanlayıcıya sahiptir. Bu süre JPG modu için 1.5 saniye ve RAW + JPG modu için 2.75 saniyedir. Bu çalışma için belirlenen tetikleyici süresi 3 saniyedir. (Anonymous 3).

**Çizelge 3.2.** Survey 3 kameranın özellikleri (Anonymous 3)

Görüntü formatı	RAW + JPG, JPG (RAW kanal başına 12 bit, JPG kanal başına 8 bit)
Lens optiği	41 ° HFOV (47mm) f / 3.0 Açıklık,% -1 Aşırı Düşük Bozulma (Balık Gözü Olmayan) Cam Lens
Yer örneklem mesafesi	2,3 cm / px (0,9 inç / px), 120 m (~ 400 ft) AGL'de
Algılayıcı	Sony Exmor R IMX117 12MP (Bayer RGB)
GPS / GNSS (Harici)	ublox UBX-G7020-KT
Pil	Çıkarılabilir Li-ion (1200mAh) (USB Destekli Olduğunda Gerekmez)
Ağırlık	50g (Pilsiz), 76g (Pilli)
Boyutlar	59 x 41,5 x 36mm (Uzunluk x Yükseklik x Derinlik)
Bellek saklama alanı	Micro SD (128 GB'a Kadar Kart) (64 GB Kart ≈ 15,000 JPG, 2,200 RAW + JPG)
Ölçüm	Ortalama / Merkez / Nokta

Çalışmada kullanılan diğer temel veri olan WV4, Digital Globe tarafından sunulmaktadır. Digital Globe çok spektrumlu, 30 cm mekansal çözünürlükte, bilinçli karar vermeyi güçlendiren, daha net ve zengin görüntüler sunmaktadır. Digital Globe'un bu kapsamda yer alan ve Şekil 3.3'te görülen en son uydusu WV4'tür.



**Şekil 3.3.** WorldView-4 uzay aracı (Anonymous 4)

Çok işlevli, yüksek çözünürlüklü bir ticari uydu olan WV4 uydusu, 617 km yükseklikte bulunmaktadır. WorldView-4, 0.30 m PAN ve 1.24 m MS çözünürlükte veri sağlamaktadır. WorldView-4, <1 günlük ortalama tekrar geçiş süresine sahiptir ve günde 680.000 km<sup>2</sup> kadar daha hızlı ve güvenilir veri toplama yeteneğine sahiptir (Çizelge 3.3).

**Çizelge 3.3.** WorldView-4 uydusunun teknik özellikleri (Anonim 2)

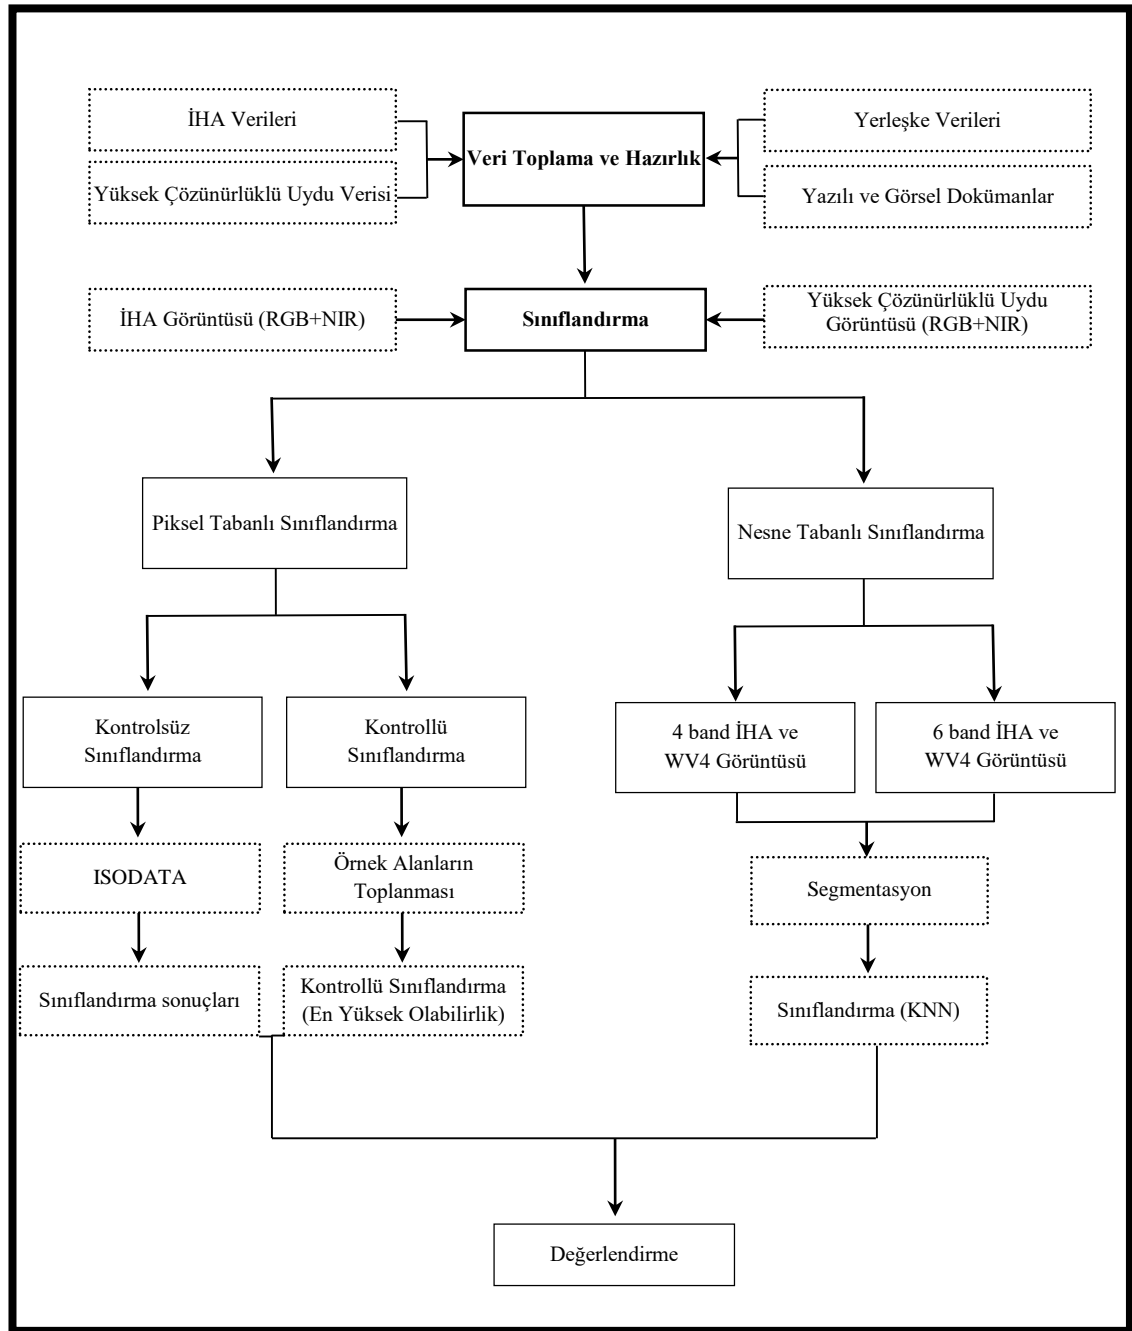
<b>Bandlar</b>	<b>PAN:</b>	450 - 800 nm
	<b>4 MS:</b>	
	Mavi	450 - 510 nm
	Yeşil	510 - 580 nm
	Kırmızı	655 - 690 nm
	Yakın Kızılötesi	780 - 920 nm
<b>Mekânsal Çözünürlük</b>	PAN Nadir	0.31 m
	20° Off -Nadir	0.34 m
	MS Nadir	1.24 m
	20° Off -Nadir	1.38 m
<b>Çerçeve Genişliği</b>	13.1 km nadir	
<b>Off-Nadir Görüntüleme</b>	Nomina olarak +/- 45 derece (off-nadir) opsiyonel daha yüksek açılar da mevcuttur	
<b>Dinamik Aralık</b>	11-bit (PAN ve MS)	
<b>Uydu Ömrü</b>	10 - 12 yıl	
<b>Yeniden Geçiş Zamanı</b> (40 derece Enlemde)	1m GSD: <1.0 gün Toplam Takım Uydular > 4.5 geçiş / günlük	
<b>Yörünge Yüksekliği</b>	617 km	
<b>Nodal Geçiş</b>	10:30 am	
<b>Coğrafi Konum Doğruluğu(CE90)</b>	<4 m CE90 (yer kontrol noktası olmaksızın)	
<b>Kapasite</b>	680,000 km <sup>2</sup> günlük	

Bu çalışmada WV4 uydusunun 24.11.2018 tarihli ve 30 cm mekânsal çözünürlüklü PAN bandı ile 1.24 m mekânsal çözünürlüklü dört MS bandının (RGB+NIR) tamamı kullanılmıştır.

### 3.3. Metot

İnsansız hava aracı ve yüksek çözünürlüklü uydu verilerinin değerlendirilmesinde piksel ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması amacı ile yürütülen bu çalışma veri toplama ve hazırlık ile sınıflandırma olmak üzere iki temel aşamadan oluşmaktadır (Şekil 3.4). Çalışmanın ilk aşaması olan veri toplama ve hazırlık aşamasında güncel tarihli ve 4 bandlı (RGB+NIR) İHA verileri, yüksek çözünürlüklü uydu verileri, yerleşkeye ait veriler ve çalışma alanına ait yazılı/görsel dokümanlar temin edilmiştir.

Ayrıca bu aşamada analize tabi tutulacak görüntülere, görüntü ön işleme ve görüntü zenginleştirme teknikleri de uygulanmıştır.



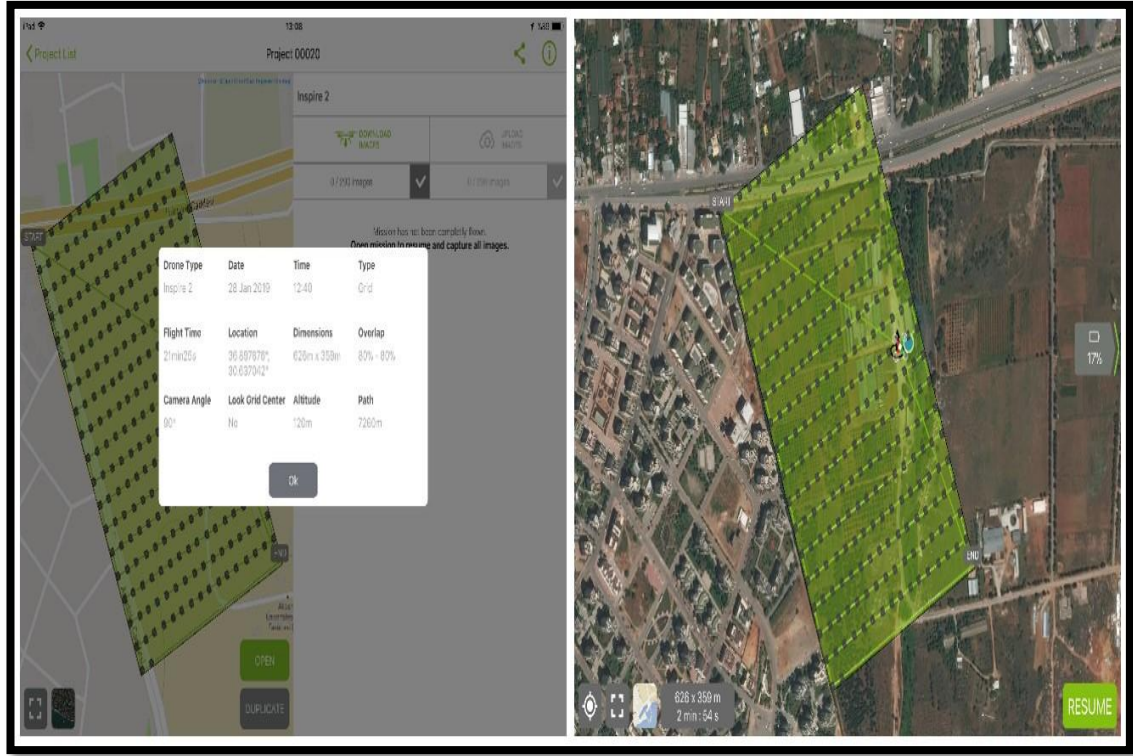
Şekil 3.4. Yöntem akış şeması

### 3.3.1. Veri toplama ve hazırlık

Farklı dalga boyu bölgelerinde kameralar kullanılarak İHA ile veri alınırken, mevcut çalışma alanı için uçuş süresi de göz önünde bulundurularak uçuş görevleri planlanmıştır (Şekil 3.5). Planlanan bu görevin aynı gün içerisinde tamamlanabilmesi amacı ile, SHGM talimatında yer alan maksimum 120 m uçuş yüksekliği tercih edilmiştir.



Bu işlem aşamasında uçuş yüksekliği ile birlikte, üst ve yan bindirme oranları, uçuş hızı, ve meteorolojik koşullar da diğer parametreler olarak göz önünde bulundurulmuştur. Bu kapsamda çalışmada, Anonymous 5 (2019) ve Dandois vd. (2015) tarafından önerilen yüksek bindirme oranları değerlendirilerek uçuş görevi 120 m yükseklikten ve % 80 üst-% 80 yan bindirme oranları ile yürütülmüştür.



Şekil 3.5. Inspire 2 uçuş planı

Çalışmanın veri toplama ve hazırlık aşamasında, İHA ile elde edilen verilerden Pix4D ve Agisoft yazılımı ile ortomozaik görüntü ve sayısal yüzey modeli üretilmiş ve bu veriler analizlere hazır hale getirilmiştir. İnsansız hava aracı ile yapılan uçuş görevleri, Sivil Havacılık Genel Müdürlüğü tarafından 22.02.2016 tarihinde yayınlanan İHA Sistemleri Talimatı (SHT-İHA)'na uygun olarak gerçekleştirilmiştir.

İnsansız hava aracı ile veri alımında mevcut RGB kameranın yanı sıra Şekil 3.6'da da görüldüğü gibi yakın dalga kızılötesi bölgede ölçüm yapabilen ikinci bir kamera da kullanılmıştır. Bu maksatla uçuş görevi için her iki kameranın da çekim anı açısından İHA'ya daha sonra monte edilen kameranın çekim hızı, üç saniyede bir olacak şekilde ayarlanmıştır.






**Şekil 3.6.** Inspire 2'ye monte edilmiş survey 3 kamera

Planlanan uçuş sonrası Zennuse X4S kamera ile 280 RGB ve Mapir Survey 3 kamera ile 457 NIR fotoğraf çekimi gerçekleştirilmiştir. Zennuse X4S kamera ile alınan fotoğraflar Pix4D yazılımı ile birleştirilerek üç band (RGB) ortomozaik görüntü ve sayısal yüzey modeli elde edilmiştir.


İnsansız hava aracına monte edilen Survey 3 kameradan elde edilen görüntülerin çekim öncesi Şekil 3.7'de görülen MAPIR kamera yansıtma kalibrasyonu zemin hedef paketi (V2) kullanılarak alınan görüntü yardımıyla kalibrasyon işlemleri gerçekleştirilmiştir.




**Şekil 3.7.** MAPIR kamera yansıtma kalibrasyonu zemin hedef paketi (V2)

Her pikseldeki yansıma değerin gerçekten doğru olup olmadığını belirlemek amacıyla yapılan kalibrasyon işleminde, yakalanan görüntünün piksel değeri hedeflerin bilinen yansıma değeri ile karşılaştırılmaktadır. Kalibrasyon işleminde Şekil 3.8’de yer alan referans görüntü ve MAPIR Camera Control (MCC) uygulaması kullanılmıştır. Bu maksatla uygulama üzerinden kullanılan kamera modeli, lens ve filtre seçilerek referans görüntü sisteme tanıtılmıştır. Daha sonra kalibre edilecek görüntüler girilerek işlem tamamlanmıştır.






Şekil 3.8. Kalibrasyon amacıyla kullanılan Survey 3 kamera referans görüntüsü



Şekil 3.9. Kalibrasyon işlemi; a) Kalibrasyon öncesi; b) Kalibrasyon sonrası

Bu aşamada çalışma alanına ait İHA verileri ve yüksek çözünürlüklü uydu verilerine layerstack, radyometrik ve geometrik düzeltme ile subset ön işleme adımları uygulanmıştır.

Bandların birleştirilmesi olan layerstack işleminde, Şekil 3.10'da da görülen İHA verileri için farklı kameralardan alınan görüntüler dört band olarak birleştirilirken, WV4 uydu görüntüsünün ise PAN ve MS bandları (RGB ve NIR) kullanılmıştır.



**Şekil 3.10.** İnsansız hava aracı layer stack işlemi; a) RGB; b) NIR; c) RGB+NIR


Çalışmanın bu aşamasında ayrıca nesne tabanlı sınıflandırmada ek iki band olarak kullanılacak olan NDVI ve SAVI indeksleri 3.1 ile 3.2 formüllerine göre hesaplanmıştır. Bu kapsamda elde edilen görüntüler Şekil 3.11'de görüldüğü gibi hem İHA hem de WV4 görüntü için oluşturularak 6 bantlı bir veri seti elde edilmiştir.



$$NDVI = (NIR - RED) / (NIR + RED) \quad (3.1)$$

$$SAVI = (1 + L) (NIR - RED) / (NIR + RED + L) \quad (3.2)$$


Uzaktan algılamada bir alandaki bitki örtüsü varlığı genellikle indeksler kullanılarak belirlenmektedir. İndeksler, görüntüyü oluşturan bandların bir takım matematiksel işlemlere tabi tutulması sonucu elde edilirler. Bu kapsamda, normalleştirilmiş fark bitki indeksi (NDVI), yeşil bitki örtüsünü analiz etmeye yarayan ve en sık kullanılan indekslerden biridir. NDVI indeks değeri -1 ile +1 arasında bir değer alır. Bu değer +1'e yaklaştığı alanlarda yüksek bitki örtüsü varlığı olduğu kabul edilir. Toprak etkisi azaltılmış bitki örtüsü indeksi (SAVI) ise, Huete tarafından NDVI'yi iyileştirme amacıyla geliştirilmiş bir indekstir. Toprak etkisi azaltılmış bitki örtüsü indeksi, NDVI'da olduğu gibi kırmızı ve kızıl ötesi dalga boylarını içeren spektral vejetasyon endekslerinden toprak parlaklığını etkileyebilecek bir dönüşüm tekniğidir. Burada L kanopi arka plan ayar faktörüdür. Yansıma uzayındaki L değerinin, toprak parlaklığı değişikliklerini en aza indirmek ve farklı topraklar için ek kalibrasyon ihtiyacını ortadan kaldırmak için olduğu bulunmuştur (Huete 1988).



Şekil 3.11. NDVI ve SAVI görüntüleri a) İHA; b) WV4

Radyometrik düzeltme işleminde, farklı radyometrik çözünürlüğe sahip iki veri için işlem uygulanmıştır. Bu kapsamda farklı radyometrik çözünürlüklü her iki veri de 16 bit olarak ayarlanmıştır. Geometrik düzeltme işleminde İHA verileri için yer kontrol noktaları olarak belirlenen noktalardan faydalanılmıştır. Daha sonra her iki veri aynı UTM projeksiyona ve WGS 84 datuma ayarlanarak gerekli düzeltmeler yapılmıştır. Subset işleminde her iki veri, belirlenen aynı çalışma alanı için kesilerek diğer işlemlere hazır hale getirilmiştir.

Bu çalışmada WV4 uydu verisinde, görüntü zenginleştirme yöntemi olan pansharpened işlemi, aynı veri için farklı bilgiler içeren veri kümelerinin kullanılmasına dayanan ve MS-PAN görüntüler için füzyon yöntemlerinden olan Gram Schmidt tekniği kullanılarak gerçekleştirilmiştir. Gram Schmidt füzyonu, düşük mekansal çözünürlüklü spektral bandlar ile PAN bandı simüle etmektedir. Simüle edilmiş PAN band ve MS bandlar için ilk band olarak kullanılan simüle edilmiş PAN band ile bir Gram Schmidt dönüşümü gerçekleştirilmektedir. Sonrasında ise yüksek mekansal çözünürlük PAN band ilk Gram Schmidt bandının yerini almaktadır. Bu yöntemde son olarak ise pansharpened oluşturmak amacı ile bir ters Gram Schmidt dönüşümü uygulanmaktadır (Laben vd. 2000). Şekil 3.12’de gerçekleştirilen pansharpened işlem sonucu görülmektedir.



**Şekil 3.12.** Çalışma alanından bir bölgeye ait WV4 pansharpened işlemi sonucu; **a)** MS görüntü; **b)** PAN görüntü; **c)** Pansharp görüntü

Veri toplama ve hazırlık aşamasında son olarak sınıflandırma sonuçlarının değerlendirilmesinde kullanmak üzere, yüksek çözünürlüklü İHA görüntüleri üzerinden manuel sayısallaştırma yöntemiyle Şekil 3.13'te görüldüğü gibi yer gerçeği verileri üretilmiştir. Bu veriler üretilirken arazi kontrolleri ile de desteklenmiştir. Bu kapsamda çalışma alanı için, daha önce belirlenen altı sınıfa göre bir vektör veri seti oluşturulmuştur.

Elde edilen yer gerçeği verilerine göre, çalışma alanı toplam 17.38 ha. olarak belirlenmiştir. Bu alanın büyük bir bölümünün 6.52 ha. ile toprak ve tek yıllık tarımsal üretim alanlarından oluştuğu, en az alana sahip sınıfların ise 0.56 ha. ile cam sera ve 0.39 ha ile plastik sera alanlarına ait olduğu tespit edilmiştir. Çalışma alanında orman sınıfını oluşturan alanların 3.23 ha. diğer sınıfını oluşturan alanların ise 4.18 ha. olduğu belirlenmiştir.



Şekil 3.13. Yer gerçeđi verisi



### 3.3.2. Sınıflandırma

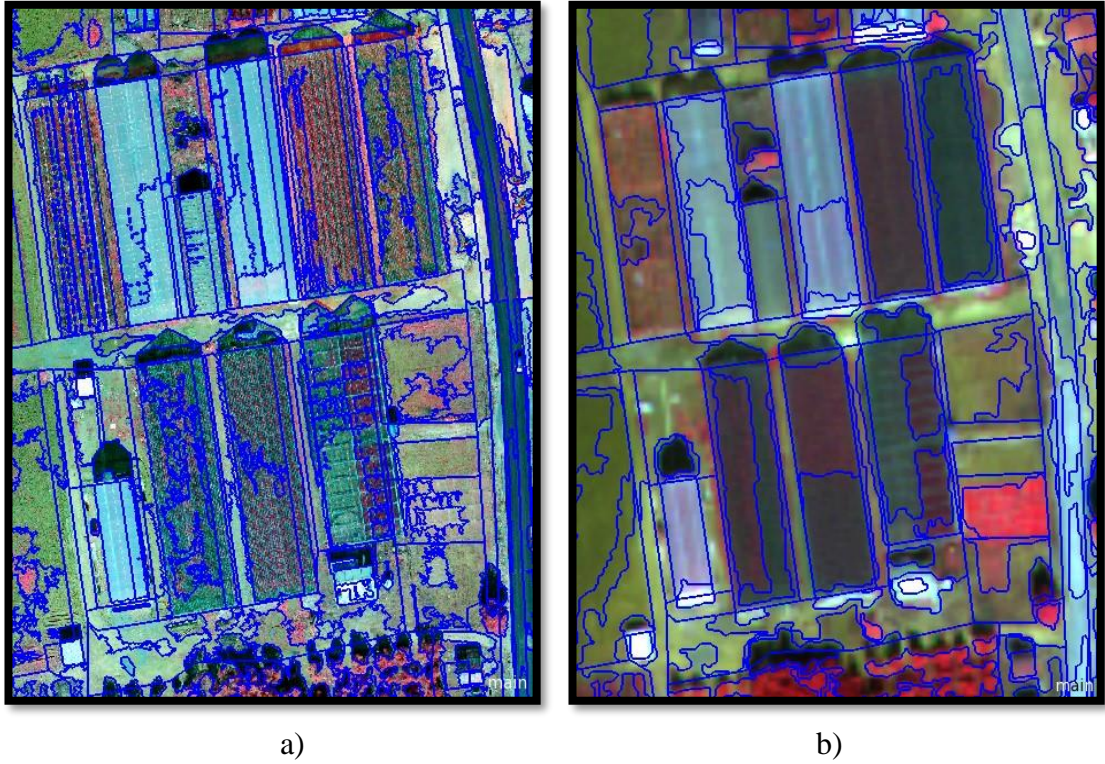
Çalışmanın ikinci temel aşaması olan sınıflandırma aşaması, piksel tabanlı sınıflandırma ve nesne tabanlı sınıflandırma olmak üzere iki alt aşamadan oluşmaktadır. Bu kapsamda ilk olarak çalışma alanı, gerek görüntüler gerekse arazi çalışmaları neticesinde altı sınıfa ayrılmıştır. Bunlar, orman, çok yıllık tarımsal üretim alanları, tek yıllık tarımsal üretim alanları ve toprak, cam sera, plastik sera ve diğer sınıflardır. Özellikle diğer sınıfa ayrılan alanlar, sınıflandırmada karışıklığa neden olabilecek baraka, eski bina, yol, hurdalık alan ve bitki atık depolama alanları olarak belirlenmiştir.

Görüntü ön işleme teknikleri uygulanan hem İHA verileri hem de yüksek çözünürlüklü WV4 uydu verisine birinci alt aşamada piksel tabanlı, ikinci alt aşamada ise nesne tabanlı sınıflandırma yöntemi uygulanmıştır.

Piksel tabanlı sınıflandırmada kontrollü ve kontrolsüz olmak üzere iki farklı teknik uygulanmıştır. Kontrolsüz sınıflandırma, eğitim verisi kullanmadan görüntüyü çeşitli algoritmalar yardımıyla kullanıcının istediği sınıf sayısına göre bölümlere ayırmaktadır. Bu maksatla genellikle, K-ortalama (K-Means) ve ISODATA algoritmaları kullanılmaktadır. Mevcut verilere her iki algoritma da uygulanmış ancak elde edilen sonuçlara göre bu çalışmada ISODATA algoritması tercih edilmiştir. ISODATA algoritması kontrolsüz sınıflandırma işlemini gerçekleştirirken iterasyonlar sonrası istatistik hesaplamasını tekrarlamaktadır. Bu yöntemde görüntü sol üst köşeden itibaren soldan sağa ve satır satır analiz edilir ve bu işlem sırasında minimum uzaklık kullanılır. ISODATA yönteminde, her bir piksel ile küme ortalama değerleri arasındaki hesaplama sonucu sınıflandırılacak piksel en yakın kümeye atanmaktadır (Canıberk 2015).

Çalışmada kullanılan diğer piksel tabanlı yöntem olan kontrollü sınıflandırmayı kontrolsüz sınıflandırmadan ayıran en önemli özellik eğitim verilerinin kullanılmasıdır. Kontrollü sınıflandırma, ilk olarak kullanıcı tarafından arazi örtü tiplerinin belirlendiği eğitim aşamasıyla başlamaktadır. Daha sonra en uygun kontrollü sınıflandırma algoritması belirlenerek görüntü sınıflandırma işlemi tamamlanmaktadır. Bu çalışmada kontrollü sınıflandırmada sıkça kullanılan en yüksek olabilirlik (Maximum Likelihood) sınıflandırıcısı kullanılmıştır. Burada kullanılan eğitim verilerinin sayısı ve temsil niteliği sınıflandırma performansı açısından önem arz etmektedir. Bu algoritmada sınıflandırma işlemine tabi tutulan pikseller en yüksek olasılık değerine göre belirlenen sınıfa dâhil olmaktadır. Çalışma alanı her ne kadar 6 sınıf olarak belirlenmiş olsa da, piksel tabanlı sınıflandırmada ilk olarak spektral karışıklığı en aza indirmek amacıyla sınıf sayısı 15 olarak belirlenmiştir. Daha sonra benzer olarak sınıflandırılmış olan alanlar birleştirilerek sınıf sayısı 6'ya düşürülmüştür.

Sınıflandırma aşamasının ikinci alt işlem adımı olan nesne tabanlı sınıflandırma yöntemiyle alanın analizinde, her iki veri seti için mevcut dört bandın yanı sıra NDVI ve SAVI indeksleri de ek band olarak kullanılmıştır. İnsansız hava aracı ve uydu görüntülerinin nesne tabanlı sınıflandırma yöntemi ile analizinin temel işlem adımı olan segmentasyon aşamasında, görüntü birbirinden bağımsız homojen nesnelere ayrılmaktadır. Bu çalışmada görüntülerin segmentasyonunda, çift bölge birleştirme tekniğine dayanan ve aşağıdan yukarıya işleyen çoklu çözünürlüklü segmentasyon (Multiresolution Segmentation) algoritması kullanılarak gerçekleştirilmiştir (Şekil 3.14).



Şekil 3.14. Segmentasyon işleminin sonucu; a) İHA; b) WV4

Çoklu çözünürlüklü segmentasyon algoritması ile görüntü nesnelere için heterojenliğin en aza indirilip homojenliğin artırılması amaçlanmıştır. Bu kapsamda en uygun ölçek parametresi, şekil ve bütünlük kriterleri uygulanarak segmentasyon işlemi gerçekleştirilmiştir. Sınıflandırmada ise piksel tabanlı sınıflandırma algoritması olan en yüksek olasılıklı sınıflandırıcısına benzer, en yakın komşu (KNN) algoritması kullanılmıştır. En yakın komşu algoritması, sınıflandırılacak nesnelere özellik alanındaki en yakın eğitim örneklerine göre sınıflandırmaktadır. Bu kapsamda sınıflandırılacak bir nesne, en yakın komşu ya da komşularının yaygın olduğu sınıfa atanmaktadır. Burada K değeri tam sayı olup, sınıflandırma işleminde dikkate alınacak komşu sayısını ifade etmektedir. En uygun K değeri verilere bağlı olarak değişmekle birlikte, daha büyük değerler sınıflandırma gürültüsünü azaltıcı etkiye sahip iken aynı zamanda sınıf sınırları daha az belirgin olmaktadır (Trimble 2014). Bu nedenle gerçekleştirilen KNN sınıflandırmasında, yazılımda varsayılan değer olarak gelen K değeri 1 olarak kullanılmıştır.

Çalışmanın doğruluk analizinde hata matrisi ve çalışma sonucunda elde edilen sınıflara ait alansal dağılımların değerlendirilmesi yer gerçeği verileri kullanılarak gerçekleştirilmiştir. Bu kapsamda son olarak İHA görüntüleri ve yüksek çözünürlüklü uydu görüntülerine uygulanan her iki sınıflandırma sonucunda elde edilen genel doğruluk değerleri ve sınıfların yer gerçeği verilerinden farklarına göre değerlendirmeler yapılmıştır.

## 4. BULGULAR VE TARTIŞMA

### 4.1. Piksel Tabanlı Sınıflandırma

Çalışmanın yöntem kısmında da belirtildiği üzere, görüntü ön işleme teknikleriyle analize hazır hale getirilen İHA ve WV4 uydu görüntülerine piksel tabanlı sınıflandırma işlemi yapılmıştır. Bu işlemde ise hem kontrolsüz hem de kontrollü sınıflandırma tekniği uygulanmıştır. Bu maksatla kontrolsüz sınıflandırmada ISODATA, kontrollü sınıflandırmada ise en yüksek olabilirlik algoritması kullanılmıştır.


#### 4.1.1. Kontrolsüz sınıflandırma

İnsansız hava aracı verilerinde yapılan kontrolsüz sınıflandırma işleminde ISODATA algoritması uygulanmış ve yapılan sınıflandırma sonucunda tüm sınıflarda karışmaların olduğu belirlenmiştir. Bu kapsamda, sınıflandırma sonucunda, toprak ve tek yıllık tarımsal üretim alanları ile diğer sınıfının birbiri ile karıştığı tespit edilmiştir. Ayrıca bu veri setinde plastik seralar başarılı bir şekilde sınıflandırılırken, bazı bina ya da barakaların da bu sınıfa dâhil olduğu ortaya çıkmıştır. Çalışmada cam seralar bu veri setinde başarılı bir şekilde tespit edilememiş, toprak ve tek yıllık tarımsal üretim alanları ile diğer sınıflar karışmıştır.

WorldView-4 uydusunda ISODATA algoritması uygulanarak gerçekleştirilen kontrolsüz sınıflandırma işleminde de, İHA veri setinde olduğu gibi WV4 veri seti için de benzer karışıklıkların olduğu, İHA sınıflandırma sonucundan farklı olarak cam seraların bazılarının tespit edildiği ancak diğer bazı alanların ise cam sera şeklinde sınıflandırıldığı ortaya çıkmıştır. Uydu verisinin kullanıldığı bu veri seti için sınıflar arasındaki farklılıkların biraz daha belirgin bir şekilde ortaya çıktığı söylenebilir de bu sınıflandırmada da, çok yıllık tarımsal üretim alanları özellikle orman alanları ve toprak-tek yıllık tarımsal üretim alanları ile karışmıştır.

Çalışmada, her iki veri de kış aylarında alınmasına rağmen uygun hava koşullarının beklenmesi nedeniyle İHA ve WV4 verileri arasında 65 günlük bir zamansal fark oluşmuştur. Sınıflar arası karışmaların fazla olmasının nedeninin, yoğun bitki örtüsüne sahip bu alanda verilerin alım tarihleri ile ilişkili olduğu değerlendirilmektedir.

Gerek İHA ve gerekse uydu verisinde uygulanan ve ISODATA algoritması kontrolsüz sınıflandırma sonuçları Şekil 4.1’de verilmiştir.



**Şekil 4.1.** Pikel tabanlı (kontROLSÜZ) sınıflandırma sonuçları

Her iki veri setinde gerçekleştirilen kontrolsüz sınıflandırma sonuçlarına ait alansal dağılımlar ise Çizelge 4.1’de verilmiştir

**Çizelge 4.1.** Kontrolsüz sınıflandırma sonucu alansal dağılımlar

Sınıflar	Pikel tabanlı sınıflandırma (Kontrolsüz)	
	İHA Alan (ha)	WV4 Alan (ha)
Orman	0.98	3,14
Çok yıllık tarımsal üretim alanları	0.92	2,84
Toprak ve tek yıllık tarımsal üretim alanları	8.17	6,46
Sera (cam)	1.79	1,65
Sera (plastik)	0.82	0,67
Diğer	4.65	2,74


Çizelgeden de görüleceği üzere, İHA görüntülerinin kontrolsüz sınıflandırılması sonucunda çalışma alanını en fazla kaplayan sınıfın 8.17 ha. ile (% 47.14) toprak ve tek yıllık tarımsal üretim alanları, en az ise 0.82 ha. (% 4.73) ile sera (plastik) olduğu görülmektedir. WorldView-4 görüntülerinin kontrolsüz sınıflandırılmasında da çalışma



alanını en fazla kaplayan sınıfın 6.46 ha. (% 37.28) ile toprak ve tek yıllık tarımsal üretim alanları, en az ise 0.67 ha. (% 3.87) ile sera (plastik) olduğu ve bu sınıflandırma sonucunun diğerine göre daha iyi olması nedeniyle alansal dağılımların farklı olduğu belirlenmiştir.

#### 4.1.2. Kontrollü sınıflandırma

Çalışma alanında her iki veri setinde gerçekleştirilen kontrollü sınıflandırma çalışmasında da sınıflar arasında önemli karışmalar meydana gelmiştir. Şekil 4.2’de görüldüğü gibi en yüksek olabilirlik kontrollü sınıflandırma sonucunda her iki veri setinde de kontrolsüz sınıflandırma sonucuna göre sınıflar arasında ayırım yapmak biraz daha kolay gibi görünse de yine de sınıflar arasında karışmaların olduğu görülmektedir. Bununla birlikte çalışmanın bu aşamasında özellikle WV4 uydu görüntüsü ile gerçekleştirilen kontrollü sınıflandırmada orman ile çok yıllık tarımsal üretim alanlarının İHA’dan elde edilen veri setine ve kontrolsüz sınıflandırma sonucuna göre daha iyi ayırt edilebildiği tespit edilmiştir. Yine kontrollü sınıflandırma sonuçları, çalışma alanının büyük bir kısmını oluşturan toprak ve tek yıllık tarımsal üretim alanları ile diğer olarak adlandırılan sınıfın daha belirgin bir şekilde belirlenebildiğini göstermiştir (Şekil 4.2).



Şekil 4.2. Piksel tabanlı (kontrollü) sınıflandırma sonuçları

Kontrollü sınıflandırma sonucu elde edilen sınıfların alansal dağılımları Çizelge 4.2’de verilmiştir. Çizelgeden görüleceği üzere, her iki veri setinde özellikle orman, çok yıllık tarımsal üretim alanları ve sera (cam) sınıflarına ait alansal değer farkları belirgin bir şekilde ortaya çıkmıştır. Alandaki sera (cam) sınıfı, İHA sınıflandırma sonucunda 2.42 ha. WV4 sınıflandırma sonucunda ise 0.69 ha. olarak tespit edilmiştir. Söz konusu bu

duruma göre, WV4 sınıflandırma sonucu ile elde edilen alansal dağılım değerlerinin İHA sınıflandırma sonucuna göre daha uygun olduğu görülmektedir.

Koç-San ve Sönmez (2016) tarafından yürütülen ve seraların tespit edilmesine yönelik olarak gerçekleştirilen çalışmada olduğu gibi, piksel tabanlı kontrollü sınıflandırma işleminde sera (plastik) sınıfı başarılı bir şekilde tespit edilmiştir.

**Çizelge 4.2.** Kontrollü sınıflandırma sonucu alansal dağılımlar

Sınıflar	Piksel tabanlı sınıflandırma (Kontrollü)	
	İHA Alan (ha)	WV4 Alan (ha)
Orman	1.06	2,94
Çok yıllık tarımsal üretim alanları	1.97	2,57
Toprak ve tek yıllık tarımsal üretim alanları	7.02	7,00
Sera (cam)	2.42	0,69
Sera (plastik)	0.37	0,34
Diğer	4.50	3,95

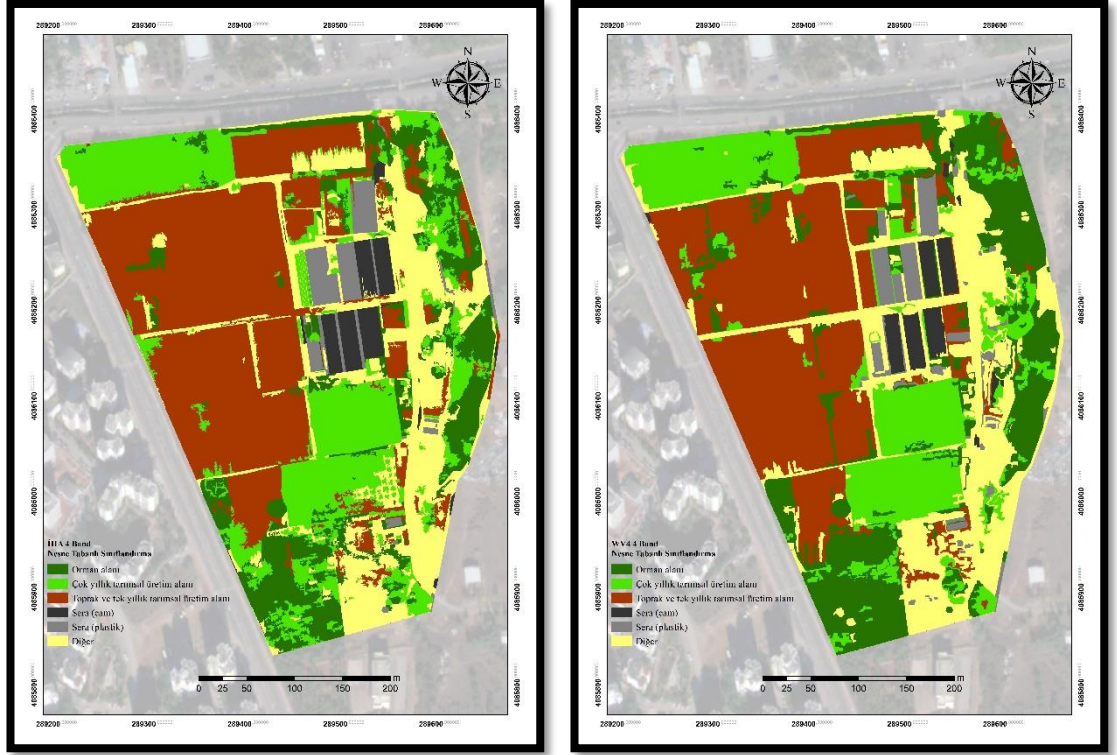
#### 4.2. Nesne Tabanlı Sınıflandırma

Çalışmada yürütülen bir diğer sınıflandırma yöntemi ise nesne tabanlı sınıflandırmadır. Bu kapsamda gerçekleştirilen nesne tabanlı sınıflandırmada, her iki veri seti için de mevcut dört band (RGB+NIR) görüntünün sınıflandırılmasının yanı sıra, kontrollü ve kontrolsüz olarak uygulanan piksel tabanlı sınıflandırma yönteminden farklı olarak kullanılan görüntülere NDVI ve SAVI indeksleri de ilave edilmiş ve altı bandlı yeni bir veri seti ile sınıflandırma işlemi gerçekleştirilmiştir.

Yapılan sınıflandırma sonucunda ise, gerek dört band gerekse altı band veri seti için nesne tabanlı sınıflandırma sonuçlarının, piksel tabanlı sınıflandırma sonuçlarına göre daha iyi olduğu sonucuna ulaşılmıştır.

##### 4.2.1. Dört band görüntünün sınıflandırılması

Nesne tabanlı sınıflandırmada ilk olarak her iki veri seti için de Şekil 4.3'te görüldüğü gibi, dört band (RGB+NIR) görüntülerin sınıflandırılması gerçekleştirilmiştir. Elde edilen her iki sınıflandırma sonucuna göre sera (cam ) ve sera (plastik) sınıflarının başarılı bir şekilde tespit edildiği ancak özellikle orman ve çok yıllık tarımsal üretim alanlarının karıştığı belirlenmiştir.



**Şekil 4.3.** Nesne tabanlı (dört band) sınıflandırma sonucu

Dört band veri setinin nesne tabanlı sınıflandırılması sonucu elde edilen ve Çizelge 4.3'te verilen alansal dağılımlardan görüleceği üzere, her iki sınıflandırma sonucundan elde edilen değerler birbirine yakın bulunmuştur. Özellikle plastik ve cam sera sınıfları başarılı sonuçlar vermiştir.

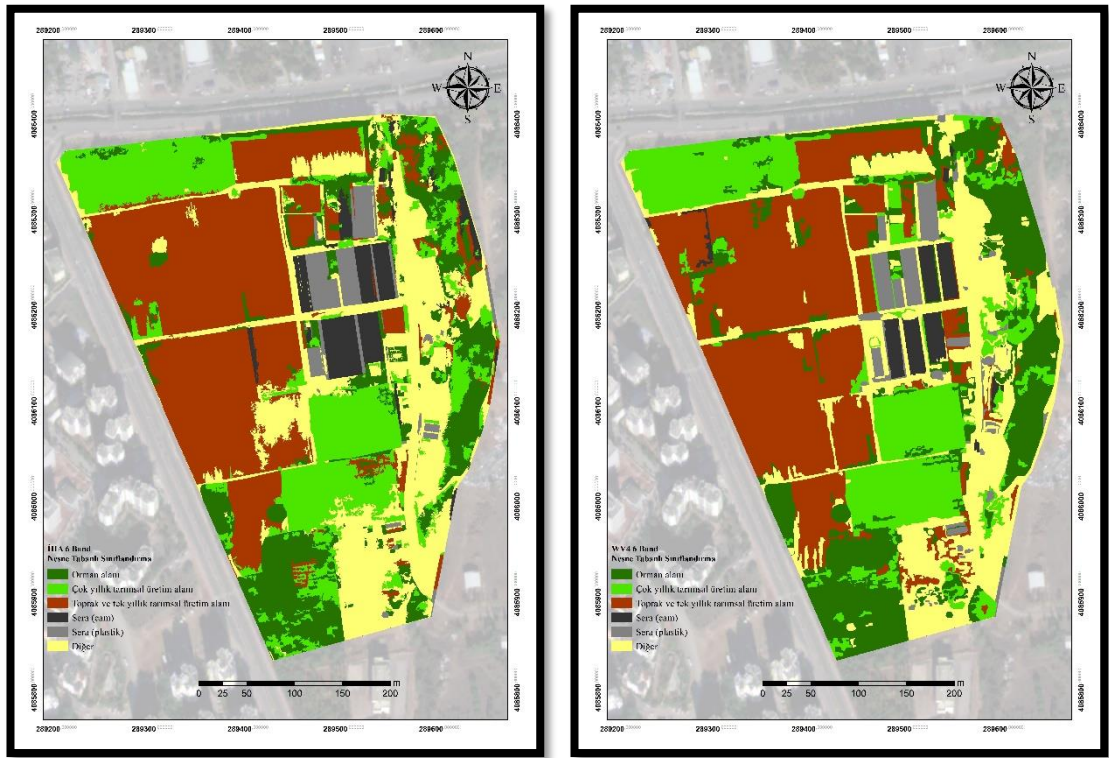
**Çizelge 4.3.** Nesne tabanlı sınıflandırma sonucu alansal dağılımlar (dört band)

Sınıflar	Nesne tabanlı sınıflandırma (4 band)	
	İHA Alan (ha)	WV4 Alan (ha)
Orman	2.50	3.43
Çok yıllık tarımsal üretim alanları	3.91	3.35
Toprak ve tek yıllık tarımsal üretim alanları	6.37	5.77
Sera (cam)	0.57	0.51
Sera (plastik)	0.61	0.62
Diğer	3.51	3.77

#### 4.2.2. Altı band (RGB+NIR+NDVI+SAVI) görüntünün sınıflandırılması

Nesne tabanlı sınıflandırma yöntemi ile mevcut dört band veri setine, çalışmanın birinci aşamasında oluşturulan NDVI ve SAVI indekslerinin eklenmesiyle elde edilen altı bandlı yeni veri setinin sınıflandırma sonuçları Şekil 4.4'te verilmiştir.

Şekilden görüleceği üzere, İHA verilerinde gerçekleştirilen altı bandlı sınıflandırma işleminde toprak sınıfı ve tek yıllık tarımsal üretim alanlarının bazı bölgelerde daha iyi belirlenmesine rağmen, çalışma alanının bazı bölgelerinde diğer sınıfı ile karışmıştır. Gerek İHA verisinde ve gerekse WV4 verisinde gerçekleştirilen sınıflandırma sonucunda hem cam sera hem de plastik seraların başarılı bir şekilde sınıflandırıldığı görülmüştür.



Şekil 4.4. Nesne tabanlı (altı band) sınıflandırma sonucu

Yapılan analiz sonucunda nesne tabanlı sınıflandırma ile elde edilen sınıfların alansal dağılımlarının birbirine ve yer gerçeği verilerine daha yakın olduğu belirlenmiştir. Bununla birlikte, nesne tabanlı sınıflandırmada kullanılan altı bandlı veri setinin sınıflandırılması ile belirlenen cam sera sınıfı İHA verisinde alansal olarak daha yüksek bir değerde bulunmuştur. Bunun nedeninin, İHA sınıflandırma sonucunda elde edilen cam seraların bazılarının aralarındaki boşlukların da cam sera olarak sınıflandırılması, şu anda kullanılmayan ve üzeri açık başka bir cam seranın da aynı şekilde bu sınıfa dâhil edilmesinden kaynaklandığı sonucuna ulaşılmıştır. Bu sınıflandırmada belirlenen bir başka karışık sınıf ise, üzeri açık olan ve içerisinde üzüm bağı yetiştiriciliği yapılan bazı sera alanlarının WV4 veri seti sınıflandırma sonuçlarına göre toprak ve tek yıllık tarımsal üretim alanı olarak sınıflandırılmasıdır.



**Çizelge 4.4.** Nesne tabanlı sınıflandırma sonucu alansal dağılımlar (altı band)

Sınıflar	Nesne tabanlı sınıflandırma (6 band)	
	İHA Alan (ha)	WV4 Alan (ha)
Orman	2.71	3.42
Çok yıllık tarımsal üretim alanları	3.47	3.33
Toprak ve tek yıllık tarımsal üretim alanları	5.87	5.81
Sera (cam)	0.83	0.54
Sera (plastik)	0.61	0.63
Diğer	4.00	3.74

Aguilar vd. (2014) tarafından yüksek çözünürlüklü veriler kullanılarak seraların nesne tabanlı sınıflandırma ile belirlenmesine yönelik yapılan çalışmada, farklı sınıflandırma algoritmaları ile farklı yüksek çözünürlüklü veriler kullanılmış ve seralar oldukça yüksek doğrulukla tespit edilebilmiştir. Aguilar vd. (2014) tarafından yapılan çalışmada olduğu gibi, her iki veri setinde gerçekleştirilen sınıflandırmada genellikle cam ve plastik sera sınıflarının iyi bir şekilde ayırt edilebildiği, orman ve çok yıllık tarımsal üretim alanlarının diğer alanlardan iyi bir şekilde ayrıldığı ancak bu iki sınıfın kendi içinde karıştığı belirlenmiştir. Toprak ve tek yıllık tarımsal üretim alanları ile diğer sınıfının ise benzer özelliklere sahip alanları içermesi nedeniyle az da olsa karışmalar olduğu tespit edilmiştir.

#### 4.3. Doğruluk Değerlendirmesi

Çalışma alanında yapılan sınıflandırmaların doğruluğunun belirlenebilmesi amacı ile yer gerçeği verilerinden yararlanılarak her iki veri seti için doğruluk analizleri yapılmıştır. Bu maksatla sınıflandırma doğruluklarının belirlenmesinde yaygın olarak kullanılan hata matrisleri oluşturulmuştur.

Hata matrislerinin oluşturulmasındaki amaç, referans ya da test verilerine karşılık gelen piksel veya nesne tabanlı sınıflandırma için segmentlerin uygun sınıflara atanıp atanmadığının belirlenmesidir. Bu maksatla çalışmanın ilk aşamasında yüksek çözünürlüklü İHA görüntüsü ve arazi kontrolleri ile elde edilen yer gerçeği vektör verisi kullanılmıştır. Bu veri üzerinden, doğruluk değerlendirmesinde kullanılacak noktalar her sınıfın alanıyla orantılı olacak şekilde rasgele belirlenmiştir. Bu maksatla yer gerçeği verisi üzerinden toplam 78 test verisi belirlenmiştir.

Çalışmada her iki veri setinin de hem piksel tabanlı hem de nesne tabanlı sınıflandırılması sonucunda belirlenen doğruluk analizi sonuçları Çizelge 4.5'te verilmiştir.

Çizelge 4.5. Doğruluk analizi sonuçları

Sınıflandırma Yöntemi / Veri Seti		İHA		WV4	
		Genel Doğruluk (%)	Kappa	Genel Doğruluk (%)	Kappa
Piksel Tabanlı	Kontrolsüz	<b>34.00</b>	0.17	40.85	0.27
	Kontrollü	45.08	0.33	<b>54.92</b>	0.45
Nesne Tabanlı	4 band veri seti	72.80	0.66	<b>66.70</b>	0.60
	6 band veri seti	<b>75.40</b>	0.69	68.95	0.62

Piksel tabanlı sınıflandırma için elde edilen en yüksek genel doğruluk değerine kontrollü sınıflandırma tekniği ile ulaşılabilmektedir. En düşük genel doğruluk değeri ise beklenildiği gibi kontrolsüz sınıflandırma tekniği ile elde edilmiştir (Weih ve Riggan 2010; Kalem 2014). Piksel tabanlı sınıflandırmada en yüksek genel doğruluk değeri % 54.92 ile WV4 veri setinden, en düşük genel doğruluk değeri ise % 34.00 ile İHA veri setinden elde edilmiştir.

Nesne tabanlı sınıflandırma yöntemi ile elde edilen sonuçlara göre İHA veri setinden alınan genel doğruluk değeri uydu verisine göre daha yüksek olarak bulunmuştur (Jumaat vd. 2018). Bu sınıflandırma sonuçlarına göre, en düşük genel doğruluk değeri % 66.70 ile WV4 uydusunun dört band veri setinde, en yüksek genel doğruluk değeri ise % 75.40 ile İHA altı band veri setinde elde edilmiştir. Sınıflandırma işleminde ek bandların kullanımının İHA veri seti için % 2.6'lık, WV4 veri seti için ise % 2.25'lik bir artışa neden olduğu tespit edilmiştir.

Hata matrisine dayanan doğruluk analizi ile elde edilen genel doğruluk değerlerine göre, KNN sınıflandırıcısı kullanılarak gerçekleştirilen nesne tabanlı sınıflandırma sonuçlarının (% 75.40) , hem kontrolsüz hem de kontrollü olarak yapılan piksel tabanlı sınıflandırmaya (% 54.92) oranla yüksek doğrulukta olduğu ortaya çıkmıştır (Kalkan ve Maktav 2010; Zoleikani vd. 2017)

Piksel tabanlı ve nesne tabanlı sınıflandırma sonuçları hata matrisinin yanı sıra, yüksek çözünürlüklü İHA görüntülerinin çok hassas bir şekilde manuel sayısallaştırma yöntemi ve arazi kontrolleri neticesinde elde edilen yer gerçeği verileri ile alansal olarak da karşılaştırılmıştır.

Çizelge 4.6’da İHA veri setinin tüm sınıflandırma yöntemleriyle elde edilen alansal dağılımlarının yer gerçeği verileri ile karşılaştırılması görülmektedir. Sınıflandırma işlemi sonuçlara göre, piksel tabanlı sınıflandırma için orman sınıfı ile yer gerçeği verisi arasında farkın -2.25 ha. olduğu belirlenmiştir. Bu yöntemde elde edilen en küçük fark değeri -0.02 ha. ile plastik sera sınıfında tespit edilmiştir. Aynı veri seti için elde edilen nesne tabanlı sınıflandırma sonuçlarına göre ise, en büyük farkın 1.41 ha. ile çok yıllık tarımsal üretim alanlarında, en küçük farkın ise 0.01 ile cam sera sınıfında olduğu görülmektedir.

İnsansız hava aracı veri seti için, piksel tabanlı sınıflandırma sonuçlarından alansal olarak en büyük fark kontrolsüz sınıflandırmada, en küçük fark ise kontrollü sınıflandırmada elde edilirken nesne tabanlı sınıflandırmada ise sınıflar arası hem en büyük hem de en küçük fark dört band veri setinden elde edilmiştir.

**Çizelge 4.6.** İnsansız hava aracı sınıflandırma sonuçlarının alansal dağılımı

Sınıflar	Sınıflandırma yöntemi								
	Yer gerçeği	Piksel tabanlı				Nesne tabanlı			
	Manuel	Kontrolsüz		Kontrollü		4 band (RGB+NIR)		4 band +2 ek band (NDVI+SAVI)	
	Alan (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)
Orman	<b>3.23</b>	0.98	<b>-2.25</b>	1.06	-2.17	2.50	-0.73	2.71	-0.52
Çok yıllık tarımsal üretim alanları	<b>2.50</b>	0.92	-1.58	1.97	-0.53	3.91	<b>+1.41</b>	3.47	+0.97
Toprak ve tek yıllık tarımsal üretim alanları	<b>6.52</b>	8.17	+1.65	7.02	+0.50	6.37	-0.15	5.87	-0.65
Sera (cam)	<b>0.56</b>	1.79	+1.23	2.42	+1.86	0.57	<b>+0.01</b>	0.83	+0.27
Sera (plastik)	<b>0.39</b>	0.82	+0.43	0.37	<b>-0.02</b>	0.61	+0.22	0.61	+0.22
Diğer	<b>4.18</b>	4.65	+0.47	4.50	+0.32	3.51	-0.67	4.00	-0.18

WorldView-4 veri seti sınıflandırma sonuçlarının alansal dağılımı ve yer gerçeği verileri ile karşılaştırılma sonuçları Çizelge 4.7’de verilmiştir. Bu sonuçlara göre piksel tabanlı sınıflandırmada aradaki farkın İHA sonuçlarına göre biraz daha düşük olduğu, en büyük fark değerinin -1.44 ha. ile diğer sınıfı için, en küçük fark değerinin ise -0.05 ha ile plastik sera sınıfı için tespit edildiği görülmektedir. Nesne tabanlı sınıflandırma sonucuna göre ise, İHA fark sonuçlarında olduğu gibi en büyük fark 0.85 ha. ile çok yıllık tarımsal üretim alanlarında, en küçük fark ise 0.02 ha. ile cam sera sınıfında tespit edilmiştir.

**Çizelge 4.7.** WorldView-4 sınıflandırma sonuçlarının alansal dağılımı

Sınıflar	Sınıflandırma yöntemi								
	Yer gerçeği	Piksel tabanlı				Nesne tabanlı			
	Manuel	Kontrolsüz		Kontrollü		4 band (RGB+NIR)		4 band +2 ek band (NDVI+SAVI)	
	Alan (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)	Alan (ha)	Fark (ha)
Orman	<b>3.23</b>	3,14	-0.09	2,94	-0.29	3.43	+0.20	3.42	+0.19
Çok yıllık tarımsal üretim alanları	<b>2.50</b>	2,84	+0.34	2,57	+0.07	3.35	<b>+0.85</b>	3.33	+0.83
Toprak ve tek yıllık tarımsal üretim alanları	<b>6.52</b>	6,46	-0.06	7,00	+0.48	5.77	-0.75	5.81	-0.71
Sera (cam)	<b>0.56</b>	1,65	+1.09	0,69	+0.13	0.51	+0.05	0.54	<b>-0.02</b>
Sera (plastik)	<b>0.39</b>	0,67	+0.28	0,34	<b>-0.05</b>	0.62	+0.23	0.63	+0.24
Diğer	<b>4.18</b>	2,74	<b>-1.44</b>	3,95	-0.23	3.77	-0.41	3.74	-0.44

WorldView-4 veri seti için piksel tabanlı sınıflandırmada, İHA veri setinde olduğu gibi alansal olarak en büyük fark yine kontrolsüz sınıflandırmada, en küçük fark ise kontrollü sınıflandırmada bulunmuştur. Nesne tabanlı sınıflandırmada ise sınıflar arası en büyük fark dört band veri setinden en küçük fark ise altı band veri setinden elde edilmiştir.

Çizelge 4.6 ve Çizelge 4.7 yer gerçeği verilerine göre sınıflar açısından değerlendirildiğinde, her iki veri için de hem cam hem de plastik seraların başarılı bir şekilde tespit edilebildiği görülmektedir. Bu kapsamda plastik seralar, İHA veri setinin piksel tabanlı sınıflandırma yöntemi ile kontrollü olarak sınıflandırılması neticesinde, cam seralar ise İHA 4 band veri setinin nesne tabanlı sınıflandırılması ile en iyi sonucu vermiştir. Çalışmada kullanılan diğer yüksek çözünürlüklü WV4 uydu veri setinde de, İHA veri setinde olduğu gibi sera sınıfları başarılı bir şekilde belirlenmiştir. Bu veri için de plastik seralar, piksel tabanlı sınıflandırma yöntemi ile kontrollü sınıflandırmada en başarılı sonucu verirken, cam seralar İHA veri setinden farklı olarak 6 band veri setinin nesne tabanlı sınıflandırılması ile elde edilmiştir.

## 5. SONUÇLAR

Akdeniz Üniversitesi Merkez Yerleşkesinde bulunan Ziraat Fakültesi üretim alanları arazisinde gerçekleştirilen bu çalışmada, İHA'dan elde edilen güncel veriler ve çalışma alanına ait yüksek çözünürlüklü WV4 uydu verileri kullanarak, piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması ve sınıflandırma sonuçlarının yer gerçeği verileri de kullanılarak değerlendirilmesi amaçlanmıştır.

Çalışma veri toplama ve hazırlık ile sınıflandırma olmak üzere iki temel aşamada gerçekleştirilmiştir. Özellikle sınıflandırma aşamasında hem İHA hem de WV4 uydu görüntüleri, tezin genel amaçlarından biri olan piksel ve nesne tabanlı sınıflandırma alt işlem adımlarına tabi tutulmuştur. Bu kapsamda her iki veri seti de piksel tabanlı ve nesne tabanlı sınıflandırma yöntemlerine göre ayrı ayrı analiz edilerek alandaki arazilerin kullanım türleri belirlenmiş ve elde edilen sınıflandırma sonuçları karşılaştırılarak başarılı olan yöntem ile veri seti ortaya konmuştur.

Bu tez çalışması sonucunda, Zerrouki ve Bouchaffra (2014) ile Başayığıt ve Ersan (2015) tarafından yürütülen piksel ve nesne tabanlı sınıflandırma yöntemlerinin karşılaştırılması çalışmalarında da olduğu gibi nesne tabanlı sınıflandırma doğruluğu piksel tabanlı sınıflandırmaya göre yüksek olarak tespit edilmiştir. Elde edilen doğruluk analizine göre, İHA görüntülerinin piksel tabanlı kontrolsüz sınıflandırılmasında en düşük, WV4 uydu görüntülerinin kontrollü sınıflandırılmasında ise en yüksek genel doğruluk değerlerine ulaşılmıştır. Nesne tabanlı görüntü analizinde ise en düşük genel doğruluk değeri WV4 uydu görüntülerinin dört band veri seti için, en yüksek genel doğruluk değeri ise Peña-Barragán vd. (2011) tarafından yürütülen ve bitki indekslerinin nesne tabanlı sınıflandırmaya katkısının araştırıldığı çalışmada olduğu gibi, İHA görüntülerinin altı band veri seti için elde edilmiştir. Bu çalışmada piksel tabanlı sınıflandırma için en düşük ve en yüksek genel doğruluk değerleri arasında % 20.92'lik bir fark oluşurken, nesne tabanlı sınıflandırmada bu farkın % 8.7 olduğu belirlenmiştir.

Son yıllarda uydu, İHA ve bilgisayar teknolojilerinde yaşanan gelişmelerle birlikte görüntü analizine yönelik olarak yapılan çalışmalar artarak devam etmektedir. Bu kapsamda özellikle çok yüksek çözünürlüklü görüntü piksellerinin spektral değerlerinin yanı sıra farklı özelliklerini de kullanmaya imkân tanıyan ve kullanıcı tarafından belirlenebilecek kural setleri ile analiz sürecine daha aktif müdahale edilebilen nesne tabanlı sınıflandırmanın kullanımı ön plana çıkmaktadır.

Hamedianfer vd. (2015) ile Çölkesen (2015) tarafından yürütülen farklı çalışmalarda da belirtildiği gibi, uzaktan algılama teknolojileri ile elde edilen çok yüksek çözünürlüklü veriler her ne kadar daha detaylı bilgiler sağlasa da, bu verilerden anlamlı örüntü gruplarının tanımlanması işlemi olan sınıflandırma yoluyla bilgi çıkarımında benzer özelliklere sahip piksellerin olması nedeniyle bir takım sorunlara da neden olabilmektedir. Bu kapsamda özellikle benzer spektral özelliklere sahip ve karmaşık yapıda pikseller içeren yüksek çözünürlüklü uzaktan algılama verilerinin analizinde klasik piksel tabanlı sınıflandırmanın yerine daha gelişmiş olan nesne tabanlı sınıflandırma yöntemi ile farklı yaklaşımların kullanılmasına ihtiyaç duyulabilmektedir. Buna göre yapılacak benzer çalışmalar için, veri alımında meteorolojik koşullar da dikkate alınarak mümkün olabilecek en yakın tarihlerin seçilmesi, aynı alanda yer alan ve

farklı büyüklüklere sahip nesnelerin segmentasyonunda farklı ölçek parametrelerinin kullanılması, spektral karışıklığa neden olabilecek arazi örtüsü ve arazi kullanımları için yersel ölçüm teknikleriyle desteklenecek yansıma karakteristiklerinin belirlenmesi ve özellikle bitki örtüsü içeren alanlarda kullanılacak indekslerin nesne tabanlı sınıflandırmaya katkısı gibi yaklaşımların dikkate alınması gerektiği değerlendirilmektedir.

## 6. KAYNAKLAR

- Adam, H., E., Csaplovics, E., Elhaja, M. 2016. A Comparison of Pixel-Based and Object-Based Approaches for Land Use Land Cover Classification In Semi-Arid Areas, Sudan. IOP Conference Series: Earth and Environmental Science. 37. 012061. 10.1088/1755-1315/37/1/012061.
- Aguilar, M., A., Bianconi, F., Fernando, J., A., Ismael, F. 2014. Object-based greenhouse classification from GeoEye-1 and WorldView-2 stereo imagery. *Remote Sensing*. 6. 3554-3582. 10.3390/rs6053554.
- Aguilar, M., A., Fernando, J., A. Andrea, V., Andrés, G., L. 2015. Object-based greenhouse horticultural crop identification from multi-temporal satellite imagery: a case study in Almeria, Spain. *Remote Sensing*. 7. 7378-7401. 10.3390/rs70607378.
- Anonim 1: <http://www.konyaalti.gov.tr/aa-anasayfa> [Son erişim tarihi: 27.02.2019].
- Anonim 2: [http://www.nik.com.tr/content\\_sistem\\_uydu.asp?id=77](http://www.nik.com.tr/content_sistem_uydu.asp?id=77) [Son erişim tarihi: 27.02.2019].
- Anonymous 1: Inspire 2 specs. <https://www.dji.com/inspire-2/specs>. [Son erişim tarihi: 03.12.2018].
- Anonymous 2: Zenmuse X4S. <https://www.dji.com/zenmuse-x4s/info#specs>. [Son erişim tarihi: 03.12.2018].
- Anonymous 3: Mapir Survey 3N camera - Red + Green + NIR (RGN, NDVI). <https://www.mapir.camera/collections/survey3/products/survey3n-camera-red-green-nir-rgn-ndvi> [Son erişim tarihi: 27.02.2019].
- Anonymous 4: Tools&Resources. <https://www.digitalglobe.com/resources#resource-table> [Son Erişim: 26.03.2019].
- Anonymous 5: How to verify that there is enough overlap between the images. <https://support.pix4d.com/hc/en-us/articles/203756125-How-to-verify-that-there-is-enough-overlap-between-the-images> [Son Erişim: 26.03.2019].
- Balçık, F., B. 2018. Evaluation of Sentinel-2 MSI data for land use / land cover classification using different vegetation indices. *Selcuk Univ. J. Eng. Sci. Tech.*, pp. 839-846, ISSN: 2147-9364.
- Başayığıt, L., Ersan, R. 2015. Comparison of pixel-based and object-based classification methods for separation of crop patterns. Scientific Papers. Series E. Land Reclamation, *Earth Observation & Surveying, Environmental Engineering*, Vol. IV, 2015 Print ISSN 2285-6064.
- Bayburt, S. 2009. Uydu görüntülerinin piksel ve nesne tabanlı sınıflandırma sonuçlarının karşılaştırılması, (Doğu Trakya Bölgesi Örneği). Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Campbell, J.,B., Wynne, R.,H. 2011. Introduction to Remote Sensing, Fifth Edition, USA.
- Canıberk, M. 2015. Hiperspektral görüntülerin eğitimsiz sınıflandırma sonuçlarının karşılaştırılması. *Harita Dergisi*, Sayı 154, 19-25.



- Chhetri, R., P., Abd-Elrahman, A., Liu, T., Morton, J., Wilhelm, V., L. 2017. Object-based classification of wetland vegetation using very high-resolution unmanned air system imagery. *European Journal of Remote Sensing*, Volume 50, Issue 1.
- Colkesen, I., Kavzoglu, T. 2017., The use of logistic model tree (LMT) for pixel- and object-based classifications using high-resolution WorldView-2 imagery. *Geocarto International*, 32 (1), pp. 71-86.
- Çölkesen, İ. 2015. Yüksek çözünürlüklü uydu görüntüleri kullanarak benzer spektral özelliklere sahip doğal nesnelere ayırt edilmesine yönelik bir metodoloji geliştirme. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Çömert, R., Avdan, U., Uça Avcı, Z., D. 2016. İnsansız Hava Aracı Verilerinden Nesne Tabanlı Bina Çıkarımı. 6. Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016), 5-7 Ekim 2016, Adana.
- Dandois, J., P., Olano, M., Ellis, E., C. 2015. Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. *Remote Sens.* 2015, 7, 13895-13920
- Duro, D., C., Franklin, S., E., Dubé, M., G. 2012. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, Volume 118, 15 March 2012, Pages 259-272.
- Elhag, M., Boteva, S. 2016. Mediterranean land use and land cover classification assessment using high spatial resolution data. *IOP Conf. Ser.: Earth Environ. Sci.* 44(4):042032.
- Hamedianfar, A., Shafri, M. 2015. Detailed intra-urban mapping through transferable OBIA rule sets using WorldView-2 very-high-resolution satellite images. *International Journal of Remote Sensing*, Vol. 36, No. 13, 3380–3396.
- Huete, A.R., (1988) A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, vol. 25, issue 3, pp. 259-309.
- Jumaat, N., F., H., Ahmad, B., Dutsenwai, H., S. 2018. Land Cover Change Mapping using High Resolution Satellites and Unmanned Aerial Vehicle. *IOP Conf. Series: Earth and Environmental Science*, 169 (2018) 012076.
- Kalantar, B., Mansor, S., B., Sameen, M., I., Pradhan, B., Shafri, H. 2017. Drone-based land-cover mapping using a fuzzy unordered rule induction algorithm integrated into object-based image analysis. *International Journal of Remote Sensing*, Volume 38, Issue 8-10.
- Kalem, E. 2014. Piksel ve nesne tabanlı sınıflandırma açısından Göktürk 2 görüntüsünün değerlendirilmesi: İstanbul boğazı örneği. Yüksek Lisans Tezi, Hava Harp Okulu Havacılık ve Uzay Teknolojileri Enstitüsü, İstanbul.
- Kalkan, K. 2011. Kentsel gelişim için potansiyel açık alanların belirlenmesinde nesne tabanlı sınıflandırma yöntemi ile transfer edilebilir kural dizisi oluşturulması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

- Kalkan, K., Maktav, D. 2010. Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (Ikonos Örneği). III. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Gebze Teknik Üniversitesi, Kocaeli.
- Karlson, M., Reese, H., Ostwald, M. 2014. Tree crown mapping in managed Woodlands (Parklands) of semi-arid West Africa using WorldView-2 imagery and geographic object based image analysis. *Sensors*, 14, 22643-22669.
- Koç-San, D., Sönmez, N., K. 2016. Plastic and Glass Greenhouses Detection and Delineation from WorldView-2 Satellite Imagery, XXIII Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS), Prague, Czech Republic, vol.XLI-B7, pp.257-262.
- Kumar, D., N. 2019. Energy Interactions with the Earth Surface <https://www.researchgate.net/publication/267962571>. [Son erişim tarihi: 27.02.2019].
- Laben, C., A., Bernard, V., Brower, W. 2000. Process for Enhancing the Spatial Resolution of Multispectral Imagery Using Pan-Sharpener, US Patent 6,011,875.
- Li, X., Myint, S., W., Zhang, Y., Galletti, C., Zhang, X., Turner II, B. L. 2014. Object-based land-cover classification for metropolitan Phoenix, Arizona using aerial photography. *International Journal of Applied Earth Observation and Geoinformation*, 33, 321–330.
- Liang, S., Li, X., Wang, J. 2012. Advanced Remote Sensing Terrestrial Information Extraction and Applications (First Edition), ISBN: 978-0-12-385954-9. USA.
- Lillesand, T.,M., Kiefer, R.,W., Chipman, J.,W. 2004. Remote Sensing and Image Interpretation (Fifth Edition). 10.2307/634969. USA.
- Lim, Y.,S., La P.,H.,Park J., S., Lee, M., H., Pyeon, M., W., Kim, J.,I. 2015. Calculation of tree height and canopy crown from drone images using segmentation. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol.33, No.6, 605-613.
- Marangoz, A., M. 2009. Uydu görüntülerinden kentsel ayrıntıların nesne-tabanlı sınıflandırma yöntemiyle belirlenmesi ve CBS ortamında bütünleştirilmesi. Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Marangoz, A., M., Görmüş, S. K., Oruç, M., Kutoğlu H. Ş., Alkış, Z. 2013. Sakarya'nın Karasu İlçesindeki Kıyı Şeridinin Landsat Görüntülerinin Nesne Tabanlı Sınıflandırma Teknikleri Kullanılarak Zamansal Analizi. TMMOB Harita ve Kadastro Mühendisleri Odası, 14. Türkiye Harita Bilimsel ve Teknik Kurultayı, Ankara.
- Maulik, U., Chakraborty, D. 2017. Remote sensing image classification. *IEEE Geoscience and remote sensing magazine*. [Son erişim tarihi: 06.03.2019]
- Meneguzzo, D., M., Liknes, G., C., Nelson, M., D. 2012. Mapping trees outside forests using high-resolution aerial imagery: a comparison of pixel- and object-based classification approaches. *Environ. Monit. Assess.*, DOI 10.1007/s10661-012-3022-1.

- Nonni, F., Malacarne, D., Pappalardo, S., Codato, D. Meggio, F. De Marchi, M. 2018. Sentinel-2 Data Analysis and Comparison with UAV Multispectral Images for Precision Viticulture. 1. 105-116. 10.1553/giscience2018\_01\_s105.
- Novelli, A., Aguilar, M., A., Nemmaoui, A., Aguilar, F., J., Tarantino, E. 2016. Performance evaluation of object based greenhouse detection from Sentinel-2 MSI and Landsat 8 OLI data: A case study from Almería (Spain). *International Journal of Applied Earth Observation and Geoinformation*, Volume 52, Pages 403-411.
- Özcan, O. 2017. İnsansız hava aracı (İHA) ile farklı yüksekliklerden üretilen sayısal yüzey modellerinin (SYM) doğruluk analizi. *Mühendislik ve Yer Bilimleri Dergisi*, Cilt 2, Sayı 1, 1-7 s.
- Peña-Barragán, M., J., Ngugi, K., M., Plant, E., R., Six, J. 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, 115 (2011) 1301–1316.
- Puissant, A., Rougier, S., Stumpf, A. 2014. Object-oriented mapping of urban trees using random forest classifiers. *International Journal of Applied Earth Observation and Geoinformation*, 26 (2014) 235–245.
- Qin, R. 2014. An object-based hierarchical method for change detection using unmanned aerial vehicle images. *Remote Sensing*, 6(9):7911-7932.
- Rastner, P., Bolch, T., Notarnicola, C., Member, IEEE, Frank Paul, F. 2014. A comparison of pixel- and object-based glacier classification with optical satellite images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, March 2014, DOI: 10.1109/JSTARS.2013.227466.
- Selim S., Sönmez, N., K., Çoşlu, M., Onur, I. 2019. Semi-automatic tree detection from images of unmanned aerial vehicle using object-based image analysis method. *Photonirvachak-Journal of the Indian Society of Remote Sensing*, vol.47, no.1, pp.193-200.
- Strasser, T., Lang, S. 2015. Object-based class modelling for multi-scale riparian forest habitat mapping. *International Journal of Applied Earth Observation and Geoinformation*, 37, 29–37.
- Sunar, F., Özkan, C., Osmanoğlu, B. 2013. Uzaktan Algılama (2.Baskı). T.C. Anadolu Üniversitesi, Yayın No: 2320, Açıköğretim Fakültesi Yayın No:1317, Eskişehir.
- Trimble, 2014. eCognition Developer Reference Book, 2014 Trimble Documentation, München, Germany.
- Weih, R., C., Riggan, N., D. 2010. Object-based classification vs. pixel-based classification: comparative importance of multi-resolution imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVIII-4/C7.
- Whiteside, T., Ahmad, W. 2005. A Comparison of Object-Oriented and Pixel-Based Classification Methods for Mapping Land Cover in Northern Australia. Proceedings of SSC2005 Spatial intelligence, innovation and praxis: The national biennial Conference of the Spatial Sciences Institute, September, Melbourne: Spatial Sciences Institute. ISBN 0-9581366-2-9.

- Zabala, S. 2017. Comparison of multi-temporal and multispectral Sentinel-2 and Unmanned Aerial Vehicle imagery for crop type mapping. Lund University GEM thesis series nr 22.
- Zoleikani, R., Zoj, M., J., V. ve Mokhtarzadeh, M. 2017. Comparison of pixel and object oriented based classification of hyperspectral pansharpened images. *Journal of the Indian Society of Remote Sensing*, 45: 25-33.
- Zerrouki, N., Bouchaffra, D. 2014. Pixel-Based or Object-Based: Which Approach is More Appropriate for Remote Sensing Image Classification? IEEE International Conference on Systems, Man, and Cybernetics October 5-8, 2014, San Diego, CA, USA.

## ÖZGEÇMİŞ

**Mesut ÇOŞLU**

**mesutcoslu@akdeniz.edu.tr**



### ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2017-2019	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı, Antalya
Lisans 2012-2018	Anadolu Üniversitesi İktisat Fakültesi, Kamu Yönetimi Bölümü, Eskişehir
Yüksek Lisans 2014-2016	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Tarım Ekonomisi Anabilim Dalı, Antalya
Lisans 1996-2000	Atatürk Üniversitesi Ziraat Fakültesi, Tarla Bitkileri Bölümü, Erzurum

### MESLEKİ VE İDARİ GÖREVLER

Mühendis 2011-Devam Ediyor	Akdeniz Üniversitesi Uzaktan Algılama Araştırma ve Uygulama Merkezi (AKUZAL), Antalya
Mühendis 2010-2011	Akdeniz Üniversitesi Yapı İşleri ve Teknik Daire Başkanlığı, Antalya

Subay	Türk Silahlı Kuvvetleri
2001-2010	Kara Kuvvetleri Komutanlığı

## **ESERLER**

### **SCI, SSCI, AHCI indekslerine giren dergilerde yayımlanan makaleler**

1- Selim S., Sönmez, N., K., Çoşlu, M., Onur, I. 2019. Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method. Photonirvachak-Journal of the Indian Society of Remote Sensing, vol.47, no.1, pp.193-200.

### **Diğer dergilerde yayımlanan makaleler**

1- Selim, S., Çoşlu, M., Sönmez, N., K., Karakuş, N. 2016. Köyceğiz Gölü ve Dalyan Kanallarında Kıyı Kenar Çizgisinin UA ve CBS Teknikleri ile Belirlenmesi, Alanda Karşılaşılan Sorunlar. Süleyman Demirel University Journal of Natural and Applied Sciences, vol.21, pp.1-7.

### **Hakemli kongre/sempozyumların bildiri kitaplarında yer alan yayımlar**

1- Çoşlu, M., Sönmez, N., K., Türkkkan, H., R. 2018. Analysis of Forest Fire with Remote Sensing and Geographical Information Systems", International Academic Research Congress, Türkiye, vol.1, pp.1827-1834.

2- Sönmez, N., K., Sönmez, S., Çoşlu, M., Türkkkan, H., R. 2018. Determination of Appropriate Areas of Apple (Malus Domestica) Cultivation with AHP and GIS Techniques. International Conference on Agriculture, Forestry Life Sciences, Budapeşte, Macaristan, vol.1, pp.130-138.

3- Türkkkan, H., R., Sönmez, N., K., Çoşlu, M. 2018. Determination of Time Changes in the Surface of Burdur Lake with Different Remote Sensing Techniques. International Academic Research Congress, Türkiye, vol.1, pp.2140-2147.

4- Türkkkan, H., R., Sönmez, N., K., Çoşlu, M. 2018. Determination of Groundwater Deposit and Water Analysis by Spatial Statistical Methods Korkuteli-Antalya Example. International Academic Research Congress, Türkiye, vol.1, pp.2356-2363.

5- Onur, I., Sönmez, N., K., Çoşlu, M. 2018. Evaluation of Vegetation Cover by Supervised Classification and Four Vegetation Indices with Sentinel 2 Image of Kemer in Antalya, Turkey. International Academic Research Congress, vol.1, pp.1993-2000.

6- Selim, S., Sönmez, N., K., Çoşlu, M. 2017. İnsansız Hava Araçları (İHA) ile Alınan Görüntülerin Kalitesini Etkileyen Faktörler. II. International Academic Research Congress, Antalya, Türkiye, 18-21 Ekim 2017, pp.675-675.

7- Çoşlu, M., Yelboğa, M., N., M., Türkkan, H., R. 2017. Organik Tarım Faaliyetinde Bulunan Ticari İşletmelerin Coğrafi Bilgi Sistemleri İle Mekânsal Analizi", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.263-270.

8- Selim, S., Sönmez, N., K., Onur, I., Çoşlu, M. 2017. Determination of the ecological connectivity between landscape patches obtained using the knowledge engineer (expert) classification technique. SPIE Remote Sensing, Varşova, Polonya, 11-14 Eylül 2017, pp.1-9.

9- Çoşlu, M., Sönmez, N., K. 2016. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Teknikleri Kullanarak İtfaiye İstasyonlarının Ulaşabilirliğinin Analizi. 6. Uzaktan Algılama-CBS Sempozyumu (UZAL-CBS 2016), 5-7 Ekim 2016, Adana, 599-606.

10- Çoşlu, M., Sönmez, N., K., Koç San, D. 2016. Object-Based Greenhouse Classification from High Resolution Satellite Imagery: a Case Study Antalya-Turkey", XXIII Congress of the International Society for Photogrammetry and Remote Sensing (ISPRS), Prag, Çek Cum., 12-19 Temmuz 2016, vol. XLI-B7, pp.183-187.

### **Kitap ve kitap bölümleri**

1- Selim, S., Çoşlu, M., Sönmez, N., K. 2018. Erişilebilirlik Analizi: Zaman ve Mekan Koordinasyonunun Sağlanmasında CBS Tabanlı Mekânsal Erişim Planlaması. Mühendislik ve Mimarlık Çalışmaları, Çiftçi, N., Yanar, Y., Ed., Çizgi Kitabevi Yayınları, Ankara, ss.1-8.

2- Türkkan, H., R., Sönmez, N., K., Çoşlu, M. 2018. Nar (Punica Granatum) Yetiştiriciliğine Uygun Alanların AHP ve CBS Teknikleri İle Belirlenmesi", Mühendislik Ve Mimarlık Çalışmaları, Çiftçi, N., YANAR, Y., Ed., Çizgi Kitabevi, ss.157-165.

3- Çoşlu, M., Sönmez, N., K., Koç San, D., Aslan, N. 2017. Sentinel-2A Görüntülerinden Nesne Tabanlı Arazi Kullanımı/Arazi Örtüsü Haritalamasında Makine Öğrenme Algoritmalarının Değerlendirilmesi", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.71-76, 2017.

4- Aslan, N., Koç San, D., Sönmez, N., K., Çoşlu, M. 2017. Landsat-8 ve Sentinel-2A Uydu Görüntülerinin Arazi Kullanımı/Arazi Örtüsü Sınıflandırma Performanslarının Karşılaştırılması. Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.65-70, 2017.

5- Sönmez, N., K., Çoşlu, M., Selim S. 2017. Farklı Çözünürlüklerdeki İnsansız Hava Aracı (İHA) Görüntülerinin Nesne Tabanlı Sınıflandırma Sonuçlarına Etkileri", Fen, Matematik, Mühendislik ve Doğa Bilimleri Araştırmaları 2017, Çiftçi, N., Kara, Y., Yalçınkaya, İ., Şahin, M., Ağaçayak, T., Ed., Çizgi Kitabevi Yayınları, Antalya, ss.57-64.

6- oşlu, M., Selim, S., Sönmez, N., K., Koç San, D. 2016. Network Analysis; Accessibility to Hospitals with Remote sensing and Geographic Information Systems Techniques: A Case Study of Konyaaltı, Antalya-Turkey. In: Recent Advances in Health Sciences, A. Adil amlı, Bilal AK, Ramiz Arabacı, Recep EFE, Eds., St. Kliment Ohridski University Press, Sofia, pp.640-647.