

**İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER  
YARDIMIYLA AĞAÇ TESPİTİ**

YÜKSEK LİSANS TEZİ

Muharrem Cihan CEYLAN

Danışman

Doç. Dr. MURAT UYSAL

HARİTA MÜHENDİSLİĞİ ANABİLİM DALI

Temmuz 2020

**AFYON KOCATEPE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER  
YARDIMIYLA AĞAÇ TESPİTİ**

**Muharrem Cihan CEYLAN**

**Danışman**

**Doç. Dr. MURAT UYSAL**

**HARİTA MÜHENDİSLİĞİ ANABİLİM DALI**

**Temmuz 2020**

## TEZ ONAY SAYFASI

Muharrem Cihan CEYLAN tarafından hazırlanan “İnsansız Hava Aracı İle Elde Edilen Veriler Yardımıyla Ağaç Tespiti” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 08 / 07 / 2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### İmza

Danışman : Doç. Dr. Murat UYSAL

Başkan : Dr. Abdullah VARLIK

Necmettin Erbakan Üniversitesi, Müh. ve Mim. Fakültesi

Üye : Doç. Dr. Murat Uysal

Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Mustafa YILMAZ

Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun

..... /..... /..... tarih ve

..... sayılı kararıyla onaylanmıştır.

Prof. Dr. İbrahim EROL

Enstitü Müdürü

## BİLİMSEL ETİK BİLDİRİM SAYFASI

Afyon Kocatepe Üniversitesi

**Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;**

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

**beyan ederim.**

08 / 07 / 2020

Muharrem Cihan CEYLAN

## ÖZET

Yüksek Lisans Tezi

### İNSANSIZ HAVA ARACI İLE ELDE EDİLEN VERİLER YARDIMIYLA AĞAÇ TESPİTİ

Muharrem Cihan CEYLAN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Harita Mühendisi Anabilim Dalı

**Danışman:** Doç. Dr. Murat UYSAL

Günümüzde teknolojinin ilerlemesi ile birlikte her konuda olduğu gibi haritacılıkta da bilgiye ulaşmak kolaylaştı. Eskiden aylar alan veri toplama aşaması, günümüzde insansız hava araçları ile kısa sürede gerçekleştirilmeye başlandı.

Yersel veri toplama yöntemlerinin aksine, insansız hava aracı ile veri toplandığında arazi ile ilgili en ufak detaylara kadar bilgi sahibi olmaya başladık. Bununla birlikte ortaya yeni bir sorun çıktı. Toplanan bu verilerin işlenmesi ile ilgili olan bu sorun, bilgisayar başında operatörlerin uzun zamanlar harcayarak verileri işlemesi ile çözülmeye çalışsa da, yeterince verimli olmadı. Bu tez çalışmasında, veri toplamada olduğu gibi verinin işlenmesi konusunda da doğruluğa dikkat edilerek, zamandan tasarruf yapma ve işlenen bu verilerin çeşitli coğrafi bilgi sistemlerine aktarılmasını hedeflenmektedir.

Tez çalışması, RGB(Red-Green-Blue) bantları bulunan iki farklı alanda yapılmıştır. Çalışmada, insansız hava aracı ile toplanan dijital görüntüler, Pix4D yazılımında değerlendirilmiş ve görüntülerden ortofoto, sayısal yükseklik modeli ve sayısal arazi modeli üretilmiştir. Üretilen bu veriler yardımı ile eCognition programında nesne tabanlı sınıflandırma yapılması hedeflenmiştir. Nesne tabanlı sınıflandırma yaparken görüntü segmentasyon aşamasında gruplara ayrıştırılıp, benzer niteliklere sahip segmentler belirlenen indis değerlerine göre sınıflandırılmıştır. Yine eCognition yazılımında kontrol verisi üretilip, hata matrisi yardımı ile doğruluk analizi yapılmıştır. Doğruluk analizi ile sınıflandırma arasındaki uyum hesaplanmıştır.

**2020, xi + 70 sayfa**

**Anahtar Kelimeler:** Hava Fotoğrafi, Ortofoto, Sayısal Yükseklik Modeli, Sayısal Arazi Modeli, Nesne Tabanlı, Sınıflandırma, Segmentasyon

## **ABSTRACT**

M.Sc. Thesis

### TREE DETECTION FROM DATA OBTAINED BY UNMANNED AERIAL VEHICLE

Muharrem Cihan CEYLAN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geomatics Engineering

**Supervisor:** Assoc. Prof. Murat UYSAL

With the advancement of technology today, it is easier to reach information in cartography as in every subject. The data collection phase, which used to take months, started to be realized in a short time with unmanned aerial vehicles.

Unlike terrestrial data collection methods, when the data was collected by unmanned aerial vehicle, we started to have information about the land, to the smallest details. However, there was a new problem. Although this problem related to the processing of this collected data was tried to be solved by the operators spending a long time processing the data at the computer, it was not efficient enough. In this thesis study, it is aimed to save time and transfer these processed data to various geographic information systems by paying attention to the accuracy of data processing as well as data collection.

The thesis was done in two different areas with RGB (Red-Green-Blue) tapes. In the study, digital images collected with unmanned aerial vehicles were evaluated in pix4D software and orthophoto, digital height model and digital terrain model were produced from images. With the help of these data, object-oriented classification is aimed in the eCognition program. When making object-based classification, segments with similar characteristics are classified according to the index values determined by dividing the image into groups during segmentation. Again, control data has been generated in eCognition software and accuracy analysis has been made with the help of error matrix.

The agreement between accuracy analysis and classification was calculated.

**2020, xi +70 pages**

**Keywords:** Aerial Photography, Orthophoto, Digital Elevation Model, Digital Terrain Model, Object Based, Classification, Segmentation



## TEŐEKKÜR

Bu arařtırmanın konusunun belirlenmesi, analiz uygulamalarının yönlendirilmesi, elde edilen analiz sonuçlarının deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu büyük katkılarından dolayı tez danıřmanım Sayın Doç. Dr. Murat UYSAL'a, arařtırma ve yazım süresince yardımlarını esirgemeyen Sayın Arř. Gör. Abdurrahman Yasin YİĐİT'e, Sayın Arř. Gör. Yunus KAYA'ya ve Sayın Öğr. Gör. Adem KABADAYI'ya her konuda öneri ve eleřtirileriyle yardımlarını gördüğüm hocalarıma ve arkadaşlarıma teőekkür ederim.

Bu arařtırma boyunca maddi ve manevi desteklerinden dolayı aileme teőekkür ederim.

Muharrem Cihan CEYLAN

Afyonkarahisar 2020

## İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET .....	i
ABSTRACT .....	iii
TEŞEKKÜR .....	v
İÇİNDEKİLER DİZİNİ.....	vi
KISALTMALAR DİZİNİ .....	viii
ŞEKİLLER DİZİNİ .....	ix
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR ÇALIŞMASI .....	2
3. MATERYAL .....	7
3.1 Ortofoto Harita Üretim Düşünce ve Süreci .....	7
3.1.1 Analog ve Analitik Ortofoto Üretimi.....	8
3.1.2 Dijital Ortofoto Üretimi .....	12
3.1.3 Ortorektifikasyon İşlemi .....	16
3.1.4 Demet Dengelemesi .....	17
3.1.5 Sayısal Ortofotoların Doğruluğuna Etki Eden Faktörler .....	17
3.1.6 Yer Kontrol Noktalarının ve Sayısal Yükseklik Modelinin Rolü.....	18
3.1.7 Sayısal Ortofotonun Çizgisel Haritalara Göre Avantajları .....	22
3.1.8 Sayısal Ortofotoların Kullanım Alanları.....	24
3.2 Segmentasyon.....	24
3.2.1 Satranç Tahtası Segmentasyonu .....	25
3.2.2 Dörtlü Ağaç Segmentasyonu .....	26
3.2.3 Kontrast Bölme Segmentasyonu.....	27
3.2.4 Çok Çözünürlüklü Segmentasyon .....	28
3.2.4.1 Ölçek Parametresi .....	29
3.2.4.2 Şekil Parametresi.....	29
3.2.4.3 Bütünlük Parametresi .....	29
3.2.5 Spektral Fark Segmentasyonu .....	30
3.3 Sınıflandırma .....	31
3.3.1 Piksel Tabanlı Sınıflandırma .....	31
3.3.2 Nesne Tabanlı Sınıflandırma .....	32
3.3.2.1 Destek Vektör Makinası (SVM) .....	32

3.3.2.2 Karar Ağaçları.....	39
3.3.2.3 Rastgele Orman (Random Forest).....	43
4. UYGULAMA.....	45
4.1 Çalışma Alanları .....	46
4.2 Görüntülerden Ortofoto, SAM, SYM Üretilmesi .....	47
4.3 Ağaç Tespiti.....	52
4.3.1 Segmentasyon İşlemi .....	53
4.3.2 Segmentlerin Sınıflandırılması .....	55
5. BULGULAR .....	59
5.1 Doğruluk Analizi .....	59
5.1.1 Kontrol Verisinin Üretilmesi .....	59
5.1.2 Hata Matrisi ile Doğruluk Değerlendirmesi .....	60
6. SONUÇ.....	65
7. KAYNAKLAR.....	66
ÖZGEÇMİŞ.....	70

## KISALTMALAR DİZİNİ

### Kısaltmalar

---

DSM	Digital Surface Model
DTM	Dijital Terrain Model
DVM	Destek Vektör Makinası
GLI	Green Leaf Index
İHA	İnsansız Hava Aracı
KIA	Kappa Index of Agreement
LiDAR	Light Detection And Ranging
nDSM	Normalized Digital Surface Model
NDVI	Normalized Difference Vegetation Index
nSYM	Normalize Edilmiş Sayısal Yüzey Modeli
OOB	Out Of Bant
SAM	Sayısal Arazi Modeli
SVM	Support Vector Machine
SYM	Sayısal Yüzey Modeli
YBO	Yeşil Bant Oranı
YKN	Yer Kontrol Noktası
YÖA	Yer Örnekleme Aralığı

---

## ŞEKİLLER DİZİNİ

	<b>Sayfa</b>
Şekil 3.1 “Matra 603” adlı ortofoto aletinin çalışma prensibi. ....	9
Şekil 3.2 “Matra 693” adlı cihazın görüntüleme düzeni. ....	10
Şekil 3.3 Çizgisel elemanlarla diferansiyel dönüşüm .....	11
Şekil 3.4 Çizgisel elemanlarla diferansiyel görüntü transferinin sayısal kontrolü.....	11
Şekil 3.5 Sayısal arazi modeli. ....	14
Şekil 3.6 Sayısal ortofoto meydana getirilirken gerçekleşen iş akışı .....	15
Şekil 3.7 Diferansiyel rektifikasyon konseptinin bir gösterimi.....	16
Şekil 3.8 Sayısal Yükseklik Modeli. ....	20
Şekil 3.9 Yer örnekleme aralığı.....	22
Şekil 3.10 Satranç Tahtası Segmentasyonu.....	25
Şekil 3.11 Satranç Tahtası Segmentasyonu Parametreleri. ....	26
Şekil 3.12 Dörtlü Ağaç Segmentasyonu. ....	27
Şekil 3.13 Dörtlü Ağaç Segmentasyonu Parametreleri. ....	27
Şekil 3.14 Çok Çözünürlüklü Segmentasyon.....	28
Şekil 3.15 Çok Çözünürlüklü Segmentasyon Parametreleri. ....	29
Şekil 3.16 Spektral Fark Segmentasyonu.....	30
Şekil 3.17 Spektral Fark Segmentasyonu Parametreleri. ....	30
Şekil 3.18 SVM sınıflandırıcı için hiper düzlem gösterimi. ....	33
Şekil 3.19 Optimum ayırıcı yüzey.....	35
Şekil 3.20 Lineer Ayrılama Durumu. ....	37
Şekil 3.21 Örnek RF ağaç modeli. ....	40
Şekil 3.22 Basit bir karar ağacı modeli. ....	41
Şekil 3.23 Hunt Algortiması.....	42
Şekil 4.1 İş Akış Şeması.....	46
Şekil 4.2 Test Alanı 1 için YKN’lerin arazi üzerindeki dağılımı.....	47
Şekil 4.3 Test Alanı 1 için Sayısal Yüzey Modeli. ....	48
Şekil 4.4 Test Alanı 1 için Sayısal Arazi Modeli. ....	49
Şekil 4.5 Test Alanı 1 için Ortofoto. ....	50
Şekil 4.6 Test Alanı 2 için Sayısal Yüzey Modeli. ....	51
Şekil 4.7 Test Alanı 2 için Sayısal Arazi Modeli. ....	51

<b>Şekil 4.8</b> Test Alanı 2 için Ortofoto. ....	52
<b>Şekil 4.9</b> Test Alanı 1 için İşlem Adımları.....	53
<b>Şekil 4.10</b> Test Alanı 2 için İşlem Adımları.....	53
<b>Şekil 4.11</b> Test Alanı 1 için Ölçek Parametresi Karşılaştırması. ....	54
<b>Şekil 4.12</b> Test Alanı 2 için Ölçek Parametresi Karşılaştırması. ....	54
<b>Şekil 4.13</b> Test Alanlarında Yüksek Objelerin Sınıflandırılması.....	55
<b>Şekil 4.14</b> Test Alanlarında Sınıflandırma Sonuçları.....	56
<b>Şekil 4.15</b> Test Alanı 1 için Sınıflandırma Sonucu. ....	57
<b>Şekil 4.16</b> Test Alanı 2 için Sınıflandırma Sonucu. ....	58
<b>Şekil 5.1</b> Destek Vektör Makineleri ile Üretilen Kontrol Verisi.....	60
<b>Şekil 5.2</b> Doğruluk Değerlendirmesi Komutu.....	63

## ÇİZELGELER DİZİNİ

	<b>Sayfa</b>
<b>Çizelge 4.1</b> Kırmızı Yeşil Mavi Bantlı Görüntüler İçin Kullanılan İndisler.....	56
<b>Çizelge 5.1</b> Örnek Hata Matrisi.....	61
<b>Çizelge 5.2</b> İkili Sınıflandırıcı İçin Örnek Hata Matrisi.....	61
<b>Çizelge 5.3</b> Test Alanı 1 için Oluşan Doğruluk Değerlendirmesi Tablosu.....	63
<b>Çizelge 5.4</b> Test Alanı 2 için Oluşan Doğruluk Değerlendirmesi Tablosu.....	64

## 1. GİRİŞ

Günümüzde hava fotoğrafları, uydu görüntüleri ve LiDAR verilerinin kullanılması ile arazi yapısı, bitki örtüsü ve diğer detaylar ile ilgili veriler üretmek ve bu verilere ulaşmak kullanıcı açısından oldukça kolay bir hale gelmiştir. Yersel veri toplama tekniklerine göre bu yöntemler her ne kadar veriyi toplamayı ve veriye ulaşmayı kolaylaştırırsa da bu verileri işleme ve coğrafi bilgi sistemlerine entegre etme süreci aynı hızda ilerleyememiştir.

Bunun üzerine verilerin işleme sürecini hızlandırmak amacı ile arazi ile ilgili detayların sınıflandırılması ile ilgili birçok çalışma yapılmıştır. Yapılan çalışmalar uzun yıllar piksel tabanlı olarak devam etmiştir. Piksel tabanlı sınıflandırmada piksellerin komşuluk ilişkileri ve renk değerleri incelenmiş olup, benzer değerleri taşıyan pikseller gruplandırılarak sınıflar oluşturulmuştur. Fakat günümüzde gerek hava fotoğraflarının, gerekse uydu verilerinin yüksek çözünürlüğe sahip olması ile piksel tabanlı sınıflandırma yöntemleri detaylar ile ilgili yeterince detaylı sonuçlar verememeye başlamıştır. Yoğun bilgiler barındıran bu görüntüleri sınıflandırma aşamasında piksel tabanlı yaklaşım piksellerin sadece spektral değerlerini incelediği için bitki örtüsü ve detaylar ile ilgili net veriler üretememiştir. Piksel tabanlı yaklaşım yerine yeni ve doğruluğu yüksek olan nesne tabanlı yaklaşım kullanılmaya başlamıştır. Nesne yapıları ile ilgili de ek veriler kullanan bu yaklaşım, pikselleri segment segment gruplandırarak anlamlı objeler oluşturur.

Ağaçlık alanların tespiti ile ilgili yapılan çalışmalar incelendiğinde birçok farklı yaklaşım kullanıldığı görülmüştür. Yapılan çalışmalarda genellikle ilk olarak ağaçlık alanlar sınıflandırılmıştır. Ağaçlık alanlar ile yeryüzündeki yeşil alanları birbirinden ayıran özelliğin yükseklik verisi olduğu, ağaçlık alanlar ile diğer yüksek objeleri birbirinden ayıran özelliğin ise renk verileri olduğu görülmüştür.

Bu yüksek lisans tez çalışmasında ise farklı kameralar ile çekilmiş hava fotoğraflarının işlenmesi ve işlenmesi sonucu oluşan veriler kullanılarak ağaçlık alanların tespitinin yapılması amaçlanmıştır. Ağaçlık alanların tespiti aşamasında nesne tabanlı sınıflandırma yaklaşımı kullanılmış olup, otomatik bir şekilde ağaçlık alanların tespiti sağlanmıştır.



## 2. LİTERATÜR ÇALIŞMASI

Kalkan ve Maktav (2010), “Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (Konos Örneği)” adlı çalışmasında şu sonuçlara ulaşmıştır: Son gelişmeler, uydu görüntülerinden arazi kullanımı ve arazi örtüsünü farklı yöntemler kullanarak belirlenmesine yardımcı olmaktadır. Piksel tabanlı sınıflandırma en iyi bilinen yöntemdir, ayrıca yüksek çözünürlüklü uydu görüntülerinin bir sonucu olarak nesne tabanlı sınıflandırma sistemi etkin bir şekilde kullanılabilir. Bu çalışmada, bu iki yöntem yüksek uzamsal çözünürlüklü IKONOS görüntüleri kullanılarak karşılaştırılmıştır. Piksel tabanlı sınıflandırma, piksellerin istatistiksel analizine dayanır, ancak nesneye yönelik sınıflandırma sistemi pikselleri toplarken, segmentasyon adımı ve bu segmentlerin renk, yoğunluk ve komşuluk gibi farklı ilişkilerini kullanmak, birçok tematik sınıf için daha anlamlı ve daha iyi sonuç elde edilebilir. Ayrıca, bulanık mantık algoritmaları ve kural seti fonksiyonu kullanan nesne tabanlı sınıflandırma yöntemi güncellenebilir bir yapıya sahiptir. En çok bilinen nesne yönelimli görüntü analiz yazılımı Definiens eCognition, piksel tabanlı yöntemle paralel sonuçlar elde eden basit ve hızlı bir "en yakın komşu" sınıflandırma algoritmasına sahiptir. Bu çalışmada birçok parametre seti, farklı ölçek faktörlerine sahip segmentasyon seviyeleri ve en yakın komşu yaklaşımı test edilmiştir. Nesneye dayalı sınıflandırma yaklaşımı birçok tematik sınıf için daha iyi sonuçlar verir Doğruluk değerlendirmeleri ve karşılaştırmalı sonuçlar gösterilmiş ve tartışılmıştır.

Li ve Shao (2012), “Object-Oriented Classification Of Land Use/Cover Using Digital Aerial Orthophotography” adlı çalışmasında şu sonuçları elde etmiştir: Çok yüksek çözünürlüklü uzaktan algılama görüntüleri kullanan arazi örtüsünün otomatik / yarı otomatik haritalamasında, en büyük zorluk, tek bir arazi kullanımının çeşitli spektral değerlere, dokulara, geometrilere ve uzamsal özelliklere sahip zemin hedefleri içermesidir. Burada, çok yüksek çözünürlüklü uzaktan algılama verilerini kullanarak arazi kullanımı ve arazi örtüsünün otomatik / yarı otomatik sınıflandırmaları için nesneye yönelik bir strateji sunulmuştur. Strateji, karakter algılama, nesne konumlandırma ve kaba sınıflandırmadan sonra sınıflandırma sonucunu adım adım rafine etmekten oluşmaktadır. Strateji, aynı seviyede veya farklı seviyeler arasında bulunan mekansal mantık ilişkilerini kullanarak spektral değerleri, dokuları ve geometrik özellikleri

fonksiyon sınıflandırmasıyla aynı seviyede bulunan nesnelerin form sınıflandırmasını birleştirmektedir. Ayrıca, form sınıflandırmasından fonksiyon sınıflandırmasına dönüşüm probleminin üstesinden gelmekte ve arazi kullanım sınıflandırmasını ve arazi örtüsü sınıflandırmasını organik olarak birleştirmektedir. Sınıflandırma sonucunun sınır çizgileri açıktır, yamalar saftır ve sınıflandırma nesnelere, çalışma sahası boyunca dağıtılan yer hedefleriyle tam olarak eşleşmektedir. Yapılan çalışmada büyük ölçekli uygulama için uygulanabilir bir teknik strateji tartışılmıştır.

Jamil ve Bayram (2017), “An Object-Based Approach For Tree Species Extraction From Digital Orthophoto Maps” adlı çalışmada şu sonuçlara ulaşmıştır: Ağaç segmentasyonu, fotogrametri ve uzaktan algılama alanında aktif ve devam eden bir araştırma alanıdır. Çeşitli ağaç türleri arasındaki hem sınıf içi hem de sınıflar arası benzerlikler nedeniyle daha zordur. Bu çalışmada, 1:5000 ölçekli dijital ortofoto haritalarından fındık ağaçlarının çıkarılması için çeşitli istatistiksel özelliklerden yararlanılmıştır. Başlangıçta vejetasyon dışı alanlar geleneksel normalleştirilmiş fark bitki örtüsü indeksi (NDVI) kullanılarak ortadan kaldırılmış, ardından pikselleri anlamlı homojen nesnelere dönüştürmek için ortalama kaydırma segmentasyonu uygulanmıştır. Yanlış pozitifleri ortadan kaldırmak için aday nesnelere morfolojik açılma ve kapanma kullanılmıştır. Ayrıca, sınıflandırma aşamasına geçmeden önce gölge ve sınırlayıcı kutu en boy oranları gibi istenmeyen etkileri ortadan kaldırmak adına bir dizi buluşsal yöntem türetilmiştir. Son olarak, fındık ağaçlarını insan yapımı nesnelere ve diğer bitki örtüsünü içeren nesnelere geri kalanından ayırt etmek için bilgiye dayalı bir karar ağacı oluşturulmuştur. Türkiye'de Giresun ilinden elde edilen 10 örnek ortofoto haritası üzerinde önerilen metodolojiyi değerlendirilmiştir. Manuel olarak sayısallaştırılmış fındık ağacı sınırları, doğruluk değerlendirmesi için referans veriler olarak alınmıştır. Hem elle sayısallaştırılmış hem de bölümlere ayrılmış ağaç sınırları ikili görüntülere dönüştürülmüş ve farklar hesaplanmıştır. Elde edilen sonuçlara göre, önerilen metodoloji, tüm örnek görüntüler için %85'in üzerinde bir genel doğruluk elde etmiştir.

Sabuncu ve Sunar (2017), çalışmalarında nesne tabanlı sınıflandırmada kullanılan kontrollü ve kontrolsüz yöntemleri uygulamışlardır ve doğruluklarını karşılaştırmışlardır. Çalışmada, 152 adet hava fotoğrafı kullanılmış olup bu fotoğraflar ile yaklaşık 1296

m<sup>2</sup>'lik afet bölgesini değerlendirmeye almışlardır. Çalışmada ilk olarak çeşitli segmentasyon yöntemleri denenmiş olup, uygulama için en uygun yöntem çok çözünürlüklü segmentasyon seçilmiştir. Çalışmada öncelikle segmentlar homojen ve heterojen olarak gruplandırılmıştır. Ardından kontrolsüz sınıflandırma yöntemi ile bazı tanımlayıcı özellikler kullanılarak ağaç sınıfında bulunduğu detaylar sınıflandırma işlemine tabi tutulmuştur. Kontrollü sınıflandırma yöntemi için ise eğitim segmentleri tanımlanmış olup, bu doğrultuda ağaç sınıfının da bulunduğu detaylar sınıflandırma işlemine tabi tutulmuştur. Homojen ve heterojen sınıflar için doğruluk değerleri sırasıyla, kontrolsüz sınıflandırmada %81, %66 ve kontrollü sınıflandırmada %92, %81 olarak hesaplanmıştır.

Gupta vd. (2014), “Object based Information Extraction from High Resolution Satellite Imagery using eCognition” adlı çalışmalarında eCognition yazılımını kullanarak ağaçlık alanlar başta olmak üzere tarım, bina ve sulak alanların sınıflandırılmasını hedeflemişlerdir. Çalışmada çok çözünürlüklü segmentasyon ve en yakın komşuluk yaklaşımları kullanılmıştır. Çok çözünürlüklü segmentasyonda bütünlük parametresi 0.1-0.5 aralığında sırasıyla denenmiştir. Bunun karşılığı olarak şekil parametresi 0.9-0.5 aralığında sırasıyla denenmiştir. Ölçek parametresi sabit 40 olarak kullanılmıştır. Yapılan bu çalışma sonucunda ağaçlık alanların sınıflandırılması ile alakalı doğruluk oranı yaklaşık %97 çıkmıştır.

Mitri (2002), “The Development of an Object-Oriented Classification Model For Operational Burned Area Mapping on the Mediterranean Island of Thasos Using LANDSAT TM Images” adlı çalışmasında, Yunanistan’ın Thasos adasında LANDSAT uydu verilerini kullanarak ormanlık alanlardaki yanan ve yanmayan ağaçların tespitini yapmayı hedeflemiştir. Segmentasyon aşamasından sonra, yapılan çalışmada tamamen yanan, kısmen yanan ve yanmayan ağaçların sınıflandırılması gerçekleştirmiş olup, yanmayan mevcutta var olan ağaçların tespiti konusunda %99’luk oranda bir doğruluk göstermiştir.

Kamps vd. (2017), “LiDAR and Orthophoto Synergy to optimize Object-Based Landscape Change: Analysis of an Active Landslide” adlı çalışmada şu sonuçları elde

etmiştir: Aktif heyelanların manzaralar üzerinde üç önemli etkisi vardır: (1) arazi örtüsü değişimi, (2) topografik değişim ve (3) yer üstü biyokütle değişimi. Çok-geçici Işık Algılama ve Aralık teknolojilerinden (LiDAR) elde edilen veriler, 2006-2012 yılları arasında Avusturya'daki Doren köyü yakınlarında aktif bir derin oturma heyelanının neden olduğu bu değişiklikleri ölçmek için çok-geçici ortofotolarla birlikte kullanılmaktadır. Arazi örtüsü, ortofotoların ve LiDAR tabanlı yükseklik verilerinin sinerjisine dayanan nesne tabanlı sınıflandırma ve içeriksel iyileştirmeler uygulanarak sınıflandırılmıştır. Topografik değişim, LiDAR türevi dijital arazi modellerinin farklılaşmasıyla hesaplanmıştır. Yukarıdaki yer biyokütlesi, allometrik denklemlerle kombinasyon halinde, ağaç üstü tespiti için bir lokal maksimum algoritma uygulanarak nicelendirilmiştir. Arazi örtüsü sınıflandırma doğrulukları 2006 için %65'ten (sadece LiDAR kullanarak) ve %76'dan (sadece ortofotolar kullanarak) %90'a (veri sinerjisi kullanarak) kadar iyileştirilmiştir. Artan doğruluklar, aktif bir heyelanın neden olduğu peyzaj değişikliklerini ölçmek için nesne tabanlı görüntü analizi kullanarak LiDAR ve ortofotoların veri sinerjisini kullanmanın etkinliğini göstermektedir. Yöntem, peyzaj değişikliği analizlerinde kullanılmak üzere daha geniş alanlara aktarılma potansiyeline sahiptir. Uygulanan yaklaşımı kullanma potansiyeli tartışılmaktadır.

Jia (2015), "Object-based Land Cover Classification with Orthophoto and LiDAR Data" adlı çalışmada şu sonuçlara ulaşmıştır: Uzaktan algılanan verilere dayalı görüntü sınıflandırması, otomatik harita araştırmalarının birincil alanıdır. Kentsel gelişimin artmasıyla birlikte, coğrafi veri tabanı güncellemesinin tutulması da çok önemlidir. Kentsel alanlardaki arazi örtüsü tiplerinin otomatik haritalanması, uzaktan algılamada en zorlayıcı problemlerden biridir. Geleneksel veritabanı güncellemesi zaman alıcı ve maliyetlidir. Genellikle manuel gözlem ve görsel yorumlama ile gerçekleştirilmiştir, Verimliliği ve doğruluğu arttırmak için veri toplama ve çıkartmada yeni teknik gittikçe gerekli hale gelmektedir. Yapılan çalışmada hem tek başına hem de entegre olarak ortofoto ve LiDAR verilerine dayanan nesne tabanlı bir karar ağacı sınıflandırmasını incelenmiştir. Dört arazi örtüsü türü, yani Orman, Su, Açık Alan ve Bina başarıyla çıkarılmıştır. Ortofoto bazlı sınıflamanın %89.2 doğruluğu ve LiDAR veri tabanlı sınıflandırmanın %88.6 doğruluğu ile umut verici sonuçlar elde edilmiştir. Hem LiDAR verileri hem de ortofoto, yalnızca genel arazi örtüsü tiplerini sınıflandıracak kadar

kapasite göstermiştir. Bu arada, ortofoto ve LiDAR verilerinin kombinasyonu %95.2 doğrulukla belirgin bir sınıflandırma sonucu göstermiştir. Entegre verilerin sonuçları çok yüksek bir örtüşme ortaya koymuştur. Sadece ortofoto veya LiDAR verilerini kullanma süreciyle karşılaştırıldığında, arazi örtüsü tipi ayrımcılığının karmaşıklığını azaltmıştır. Ayrıca, başka bir sınıflandırma algoritması, destek vektör makineleri (SVM) sınıflandırması önceden oluşturulmuştur. Karar ağacı sınıflandırmasına kıyasla, ortofoto veri kümesinde (%89.2) ve entegrasyon veri kümesinde (%97.3) karar ağacı sınıflandırması ile aynı doğruluk seviyesini elde etmiştir. Ancak, LiDAR veri kümesinin SVM sonuçları tatmin edici olamamıştır. Genel doğruluğu sadece %77.1'e ulaşmıştır. Kısacası, nesne tabanlı arazi örtüsü sınıflandırması, arazi örtüsü harita üretiminde etkinliğini göstermiştir. Spektral ve uzamsal özellikleri giriş verilerinden verimli bir şekilde kullanılabilir ve görüntüyü yüksek doğrulukla sınıflandırabilir.

### 3. MATERYAL

#### 3.1 Ortofoto Harita Üretim Düşünce ve Süreci

Ülkemizde ilk ortofoto üretim süreci Harita Genel Komutanlığı tarafından başlatılmıştır. 1925 senesinde resmi kuruluşunun ardından hem yersel hem de hava fotoğrafçılığı metodlarıyla çekilen fotoğrafların banyo işlemlerinde uzun yıllar siyah – beyaz teknoloji kullanılmıştır. Aynı şekilde kontak baskı büyütme – küçültme işlemlerinde de aynı teknolojik unsurlar kullanılmıştır. 1982 senesinden sonra rulo hava filmlerinin banyolama işlemlerinde otomatik devreler sisteme sokularak analitik ortofoto üretimine başlanmıştır. Bunun yanında banyolama işlemleri için çeşitli otomatik sistemler alınmasına rağmen yüksek ücretlerinden dolayı kısa bir zaman aralığında kullanılabilmiştir. Fakat gelişen teknoloji ve azalan maliyetleri sonucu 1996 senesinden sonra kontak baskı ve laboratuvar işlerinde otomasyon sistemleri kullanılmaya başlanmıştır. Yerleşim merkezlerini kapsayan ortofotolarda renkli fotoğraflar, ormanlık alan tespiti ve çekimindeyse renkli kızılötesi fotoğraflar tercih edilmiştir (Şahin 2007).

Bilgisayar teknolojisinin ivme kazanması ve oldukça fazla gelişmesinden dolayı analog ortofoto üretiminde yaşanan problemler tamamen yok olmuştur. Analog ortofoda yapımından önce planlanan projede yüzde doksan yan bindirmeli fotoğraflar çekilecek şekilde plan yapılarak, haftada bir resim ancak kapatılabilmekteydi. Fakat dijital sistemlerde meydana getirilen fotoğrafların sayısal olmasından dolayı çok daha kolay bir şekilde görüntüler sağlanmaktadır (Şahin 2007, Yılmaz 2002).

Sayısal ortofoto üretiminde esas olan yöntemin temeli kamera konum matrisinin, yer konum sistemindeki görüntü konum matrisine dönüştürme prensibine dayanmaktadır. Sayısal ortofoto üretim süreci, YKN mekanizmasının X ve Y düzleminde bulunan fotoğraf matrisinin oluşturulmasıyla başlayarak bahsedilen elemanların merkezlerinin kamera konum mekanizmasına dönüşmesiyle devam etmektedir. Bu dönüşüm için XY girdisi noktalarının Z konumlarına ihtiyaç duyulur.

Söz konusu veriler, analitik analiz aletlerinde ölçülen yakın grid noktaları ağından elde edilmektedir. Sayısal yükseklik modeli (SYM) verileri bir X ve Y konum ağındaki her


noktanın Z konumunun bulunmasını sağlamaktadır (Şahin 2007, Yılmaz 2002).

Geleneksel yöntemlerle dijital ortofoto üretiminde görüntü verisi çoğunlukla hava fotoğrafları sayesinde temin edilmektedir. Bunun yanında uydu verilerinden ya da farklı kaynaklardan da temin edilebilmektedir. Devam eden süreçte görüntü verisi, her pikselden alınarak teker teker işlenmektedir. Yeryüzündeki bilinen konumlarının ya da kamera pozisyonlarının direkt olarak belirlenmesi, hesapların yapıldığı konum referans çerçevesini belirlemek için kullanılmaktadır. Devam eden süreçte ortofoto üretim işlemleri tekrar edilmektedir.

Ortofotoların blok halinde birleştirilmesi gerekmektedir. Bu işlem içinse ortofoto mozaiklerini temin etmek ve temsil etmek için blok olarak birleştirilmelidir. Ortofotoların tamamı belirli bir projeksiyonda meydana geldiklerinden geometrik düzlemde hiçbir problemle karşı karşıya gelinmemektedir. Fakat birleştirilen ortofotoların parlaklık seviyeleri farklı olduğu zaman açığa çıkan esas sorun, analitik yöntemde uygun bir uçuş planıyla giderilirken, dijital fotoğraflamada bu şekilde bir sınırlandırma görülmez (Şahin 2007, Yılmaz 2002).

### **3.1.1 Analog ve Analitik Ortofoto Üretimi**

Gerek analog gerekse analitik metotlarla ortofoto süreçlerinde analog fotoğraflar kullanılmaktadır. Metrik fotoğraflarda görülen yıpranma ve bozulmalar, fotoğrafların çok küçük parçalar olarak yatay konuma getirilmesiyle ancak giderilmektedir. Analog metot ile beraber ortofoto üretiminde Şekil 2.1’de gösterilen “*Matra 693*” aletinin çalışma prensibi açıklanarak ifade edilmiştir.



Şekil 3.1 “Matra 603” adlı ortofoto aletinin çalışma prensibi.

Şekil 3.1’de görüldüğü üzere alette sol resim kırmızı filtreyle sağ resimse mavi filtreyle aydınlatılmaktadır. İncelemeyi gerçekleştiren operatör, ifade edilen renklere uyumlu bir gözlük takarak gözlemine gerçekleştirmektedir. Model alanındaysa filmi ışıktan korumak için film taşıyıcısı bulunmaktadır. Söz konusu taşıyıcı üzerindeyse görüntüleme penceresi ismi verilen ve “Y” ekseninde hareket eden bir perde daha bulunur. Görüntüleme penceresi analog cihazlardaki ölçü markasına tekabül etmektedir.


Cihazda stereo model temin edilir ve bu modelin kesin yöneltmesi yapılmaktadır. Operatör, gözlükle modeli incelerken “X” yönünde hareketi sağlanan görüntüleme penceresini ölçü markası gibi araziye teğet tutar. Dolayısıyla filmin barındığı taşıyıcı aşağı ve yukarı hareket etmektedir. Bir profil bu sayede tamamlandıktan sonraki süreçte büyük perde otomatik bir biçimde “X” yönünde hareket ederek profillemeye işlemine devam edilir.

Film taşıyıcısının üzerinde bulunan film eğer ortokromatik bir filmse, kırmızı ışıktan etkilenmez ve yalnızca diğer görüntüden gelen mavi ışıkla pozlama yapar. Bu şekildeki bir durumda gerek modelin gözlenmesi gerekse pozlamanın yapılabilmesi için ortofoto



sisteminin yalnızca kırmızı ışıkla aydınlatılmış ve onun dışında tamamen karanlık bir odada kalması gerekmektedir.

Böylece bu karanlık kırmızı ışıklı odada ortofoto temin edilirken aynı zamanda görüntüleme penceresini araziye paralel olarak tutmak için bir ölçek düzeltilmesi gerekir. Bunun yanında modelden, ortofoto için bir büyütme işlemine tabii tutulmayıp ortofotoyla model ölçeği aynı ölçeğin içerisinde bulunmalıdır (Arslanbek 2009, Kraus 1993). Şekil 3.2’de “Matra 693” adlı ortofoto cihazının görüntüleme düzeni görülmektedir.



Şekil 3.2 “Matra 693” adlı cihazın görüntüleme düzeni.


Modern diferansiyel rektifikasyon teorisi, fotoğrafların bozulma ve yıpranma (deformasyon) teorisine dayanmaktadır. Söz konusu köşe noktalarının konumları  $\zeta$  ve  $\eta$  olan yıpranmış bir fotoğrafın kare gridli yeni bir fotoğrafa çevrilmesi amaçlanmaktadır. Bu noktada temel amaç, rastgele bir dörtgenin fotoğrafik içeriğini bir kareye dönüştürmektir. (Kraus 1993);

“Bu bilineer dönüşüm aletsel olarak çeşitli şekillerde tanımlanabilir. Çok dar bir “S” uzunluğunun kesiti, kare gridin genişliği, ortofotonun “XY” düzlemi üzerinde “Y” yönünde hareket ettirilirken,  $\zeta\eta$  düzleminin bir elemanı, XY düzlemine izdüşürülmektedir. Fotoğrafın çizgi elemanlarla dönüşümü”;

- Merkez noktanın iki ötelenmesi ( $c' c$ ),
- $\alpha$  açısı boyunca döndürme,


- Ölçeğin değiştirilmesi ( $s'$   $s$ ) ile gerçekleştirilir.

Bu fotoğrafın çizgisel elemanlarla diferansiyel dönüşümü Şekil 3.3'de gösterilmektedir.



Şekil 3.3 Çizgisel elemanlarla diferansiyel dönüşüm (Arslanbek 2009).

Bunun yanında çizgisel elemanlarla diferansiyel görüntü transferlerinin sayısal kontrolü Şekil 3.4'de gösterilmektedir.



Şekil 3.4 Çizgisel elemanlarla diferansiyel görüntü transferinin sayısal kontrolü.

Denetleme bilgisi grid köşelerindeki  $\zeta\eta$  ve  $xy$  konumlarından hesaplanır. “y” tarafındaki tüm profil çizgisince doğrusal olarak enterpole’si sağlanmış sabit sayıdaki kısımları,

komşu profildeki kısımlara birleştiren çizgiler ortofotolardaki çizgisel elemanları temsil eder, onların enterpole edilen uç kısımlarından görüntüde karşılık gelen çizgi elemanların uç noktalarının  $\zeta\eta$  konumları hesaplanır.

Objeye yüzeyinin bir XY gridinin Z konumlarıyla tanımlandığı varsayılırsa, ortofoto meydana getirmek için, objeye yüzeyinin XY düzlemine dik izdüşümü, objeye grid kısımlarının XYZ kısımlarını fotoğraf düzlemine merkezi izdüşümle çevirerek meydana getirilebilir. Sonuçta elde edilen  $\zeta\eta$  konumları yıpranan gridi tanımlar ve diferansiyel rektifikasyon sonucunda yıpranmış gridin kare gride dönüştürüldüğü ortofoto elde edilir (Arslanbek 2009, Kraus 1993).

### 3.1.2 Dijital Ortofoto Üretimi

Ortofoto haritası meydana getirileceği zaman görüntülerin alınacağı konuma ait hava fotoğrafları ya da uydu görüntüleri, kullanılacak kameranın iç yöneltme mekanizmaları ve her çekime ait dış yöneltme elemanlarıyla beraber rektifiye edilecek olan objelerin yüksekliklerinin bulunması için bölgeye dair sayısal yükseklik modeli dijital ortofoto yapımı için kullanılmakta olan girdiler olarak karşımıza çıkmaktadır (Yastıklı 2009).

Sayısal yapılan ortofoto meydana getirmenin temeli, kamera konum sistemindeki fotoğraf konumlarının, yer konum sistemindeki görüntü konumlarına çevrilmesi esasına dayanmaktadır. Sayısal ortofoto meydana getirilmesinde, yer kontrol sisteminin XY düzlemindeki fotoğraf matrisi belirlenir ve bu elemanların merkezleri kamera konum mekanizmasına çevrilir. Bu dönüşüm için X ve Y gridindeki noktaların Z konumlarına gereksinim vardır. Bu veriler, analitik değerlendirme cihazlarında ölçülen yakın grid kısımlarından temin edilmektedir. SYM verileri bir X ve Y konum ağındaki bütün noktaların Z konumlandırmasını sağlamaktadır (Şahin 2013, Yılmaz 2002).

Dijital ortofoto meydana getirmek için farklı metotlar uygulanmaktadır. Örneğin ilk olarak sayısal hava fotoğrafları ve uydu fotoğraflarının her ikisi de rektifiye edilebilmektedir. Bu yöntemler polinomal, projektif ve diferansiyel rektifikasyonlar olabilmektedir. Bunlardan baştan iki tanesi kamera uyumu ve geometrisi bulunmadan ortofotoyla fotoğraf arasındaki analitik değişimi tanımlamaktadır.


Bahsedilen bu yöntemler çözüme biraz yaklaştırmaktadır. Diğer bir yöntemse, fotoğraf işleme esnasında model ve gerçek nesne veya arazi arasındaki bağı oluşturan doğrusallık koşulu ve rölyef yer değiştirmenin düzeltilmesi olarak karşımıza çıkmaktadır. Kamera donanımındaki distorsiyonları elimine etmek için ek parametreler kullanılmaktadır. Bu durum, doğrudan fotoğrafların video kameralarla çekildiği zamanlarda gerekli bir durum olarak karşımıza çıkmaktadır.

Dijital ortofoto harita üretim süreci aşağıda belirtilen aşamalardan meydana gelmektedir: “Ortofoto harita üretim sürecinde öncelikle ortofoto haritası üretilecek olan alan belirlenmektedir. Daha sonra bu alanda havadan alınan görüntülerinin görüntü koordinatlarını arazi koordinatlarına paralel ve uyumlu hale getirebilmek için ve görüntülere zeminle uyumlu anlamlı koordinatların kazandırılabilmesi için görüntü alımından önce arazide jeodezik çalışmalar gerçekleştirilir” (Tufan 2012).

“Bu kapsamda arazide yer kontrol noktaları işaretlenir, koordinatları ölçülür ve uçuş işlemleri gerçekleştirilir. Uçuş işlemi esnasında hava aracında bulunan GPS kullanılarak kameranın anlık konumu bulunurken, IMU sistemiyle dönüklükler belirlenmektedir. Görüntü alma işlemleri sonrası ortofoto üretiminin temel aşaması olan hava görüntülerini arazi koordinatlarıyla ilişkilendirebilmek için blok dengeleme (havai nirengi) yapılmaktadır” (Tufan 2012, Jacobsen 2000).

Fotogrametrik yöntemin esas amacı, bilinen yer denetim noktalarından yararlanarak en az iki fotoğrafta elde edilebilen noktaların arazi konumlarının, resimler ya da modeller üstünde yapılan konum çeşitlerinden hesaplanmasıdır. Dengeleme metodu olarak ışın demetleriyle blok dengeleme metodu kullanılmaktadır. Işın demetleri ile blok dengeleme metodunda bir stereo fotoğraf çiftinde her bir resme dair ışın demetleri sayısal olarak nitelendirilir ve bu ışın demetlerinin ilgili kısımlarda kesiştirilmesi sağlanır. Bu metotta iki fotoğrafa dair 12 tane dış yöneltme elemanı ve yeni noktaların (kolon ve model bağlama noktaları) konumları bilinen kontrol kısımlarından faydalanarak hesaplanmaktadır (Tufan 2012, Jacobsen 2000).

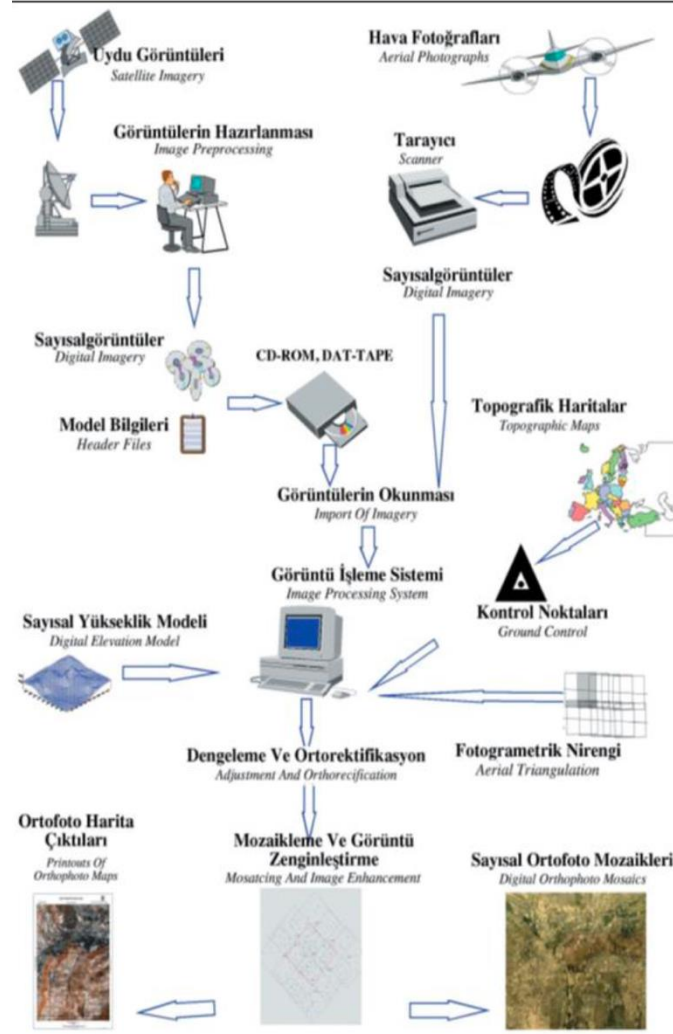
Blok dengeleme sürecinden sonra sayısal arazi modeli meydana getirilmektedir. Sayısal arazi modeli, arazi temelinin ve yüzeyin açıkça meydana çıkan topografik niteliklerinin dağınık bir şekilde dağılmış kısımlarla beraber arazinin su ayırım ve su toplama kısımlarının arazinin gerçek şeklinin daha iyi bir şekilde sayısal olarak ortaya konulmuş halidir (Tufan 2012, Jacobsen 2000). Şekil 3.5’de sayısal arazi modeli örneği gösterilmektedir.



Şekil 3.5 Sayısal arazi modeli(İnt.Kyn.1).

Sayısal arazi modeli meydana getirme işlemlerinden sonra ortorektifikasyon işlemi uygulanmaktadır. Çekilen hava fotoğrafları, arazinin topografyasını, dünyanın eğikliğini ve kameranın pozlama yaptığı konum gibi birçok faktörden dolayı geometrik deformasyonlara uğramaktadır. Bu problemleri ortadan kaldırarak ham fotoğraftan doğru ortofoto meydana getirme işlemineyse ortorektifikasyon adı verilmektedir.

Ortorektifikasyon işleminden sonra devam eden süreçte üretilen ortofotoların bir araya getirilmesiyle beraber ortofoto mozaik oluşturulmaktadır. Sayısal ortofoto meydana getirilirken yapılan işlerin sıralaması ya da akışı Şekil 3.6’da gösterilmektedir.




Şekil 3.6 Sayısal ortofoto meydana getirilirken gerçekleşen iş akışı (Akdeniz 2004).

Ortofolar çeşitli bloklar halinde birleştirilmektedir. Bu durumun esas sebebiyse ortofotonun mozaiklerini temin etmek, böylece geniş bir araziyi yalnızca bir tane ortofotoyla göstermek için yapılmasıdır. Ortofotoların tamamı belirli bir projeksiyonda meydana getirdiklerinden dolayı geometrik olarak bir sorunla karşı karşıya kalmamaktadır. Ancak birleştirilen ortofotoların parlaklık değerlerinin birbirlerinden değişik olmaları sorunu, analitik metotlara uyan bir uçuş planı gerçekleştirilerek giderilebilir. Fakat dijital fotogrametride bu şekilde bir sınırlamadan bahsedilemez (Şahin 2007, Yılmaz 2002).

### 3.1.3 Ortorektifikasyon İşlemi

Çekilen bir hava fotoğrafı veya bir görüntünün içinde yer alan çeşitli durumlardan dolayı ortaya çıkan geometrik hataları düzeltme işlemine ortorektifikasyon işlemi denilmektedir. Bu işlemin ardından meydana getirilen ortofotoda, arazinin bulunduğu coğrafyanın konumu, uzunlukları, açıları ve alanları doğru bir şekilde ölçülmektedir (Şekil 3.7).



Şekil 3.7 Diferansiyel rektifikasyon konseptinin bir gösterimi (Şahin 2007).

Şekil 3.6'da gösterilen metod genellikle diferansiyel rektifikasyon olarak isimlendirilen işlemdir. Şekilde ifade edilen “P” noktası rölyef yer değiştirmesi sonucunda harita üzerinde “P'” konumunda görüntülenir. “P” noktasını içeren rektifikasyon parçasının sınırları içindeki araziye ait ortalama yüksekliğe bir rektifikasyon düzlemi konulur ve ortogonal projeksiyon meydana getirilir.

Dijital fotogrametri gibi sayısal bir ortamda, böyle işlemler için dijital fotoğraflar kullanılmaktadır. Bu dijital fotoğraflar, bir rektifikasyon düzlemine ayrı ayrı pikseller diferansiyel şekilde çevrilir. Böylece sayısal olarak bir harita düzlemine, dönüklük ve rölyef yer değiştirmeleri giderilmiş olarak izdüşürülmüş olurlar. Şekil 3.5'de gösterilen arazi profili, sayısal bir fotoğraftaki bir tarama satırı olarak ifade edilebilir. Eğer ortofotoyla, ham görüntü piksellerinin içinde tuttuğu alan birebir eşlenirse, bu durumda bir rektifikasyon düzleminin fotoğraf pikseline karşılık geldiği görülmektedir.

### 3.1.4 Demet Dengelemesi

Bu yöntem, çok açılı ve yüksek doğruluğa sahip bir çözümleme tekniği olarak karşımıza çıkmaktadır. Bu metod ışın demetlerinin ortak noktada kesiştirilmesi esasına dayanmaktadır. Bu metod sayesinde stereo resim çiftindeki iki farklı resme ait ışın demetleri sayısal olarak yöneltilerek iki resme de ait 12 tane dış yöneltme elemanı ve yeni noktaların konumları bilinen kontrol noktası konumu yardımıyla hesaplanmaktadır.

Dengelemenin matematik modeli doğrusallık (kolinearite) şartına dayanmaktadır. Doğrusallık şartı, bir arazi noktasının, izdüşüm merkezinin ve resmin orta noktasının obje uzayındaki karşılığının aynı ışın demetine denk gelmesi şartına bağlanmaktadır.

Dengelemenin matematik modeli olan doğrusallık koşulu denklemleri 3.1 ve 3.2 numaralı denklemlerde gösterilmektedir:

$$x_a = z_p - c \frac{r_{11}(x_a - x_0) + r_{21}(y_a - y_0) + r_{31}(z_a - z_0)}{r_{13}} \quad (3.1)$$

$$y_a = y_p - c \frac{r_{12}(x_a - x_0) + r_{22}(y_a - y_0) + r_{32}(z_a - z_0)}{r_{13}(x_a - x_0) + r_{23}(y_a - y_0) + r_{33}(z_a - z_0)} \quad (3.2)$$

Şeklinde olarak ifade edilir. Burada: **xa, ya**: resim koordinatları,  $X_a, Y_a, Z_a$  : yer koordinatları, “**r**” katsayıları: görüntü koordinat sistemi ile arazi koordinat sistemi arasındaki dönüklük matrisinin elemanları ve **xp, yp, c**; iç yöneltme parametreleri olarak tanımlanmaktadır.

Dengelemenin doğruluğu, kontrol noktalarının gerçekliğine, dağılımına ve sayısına bağlı olarak gelişmektedir. Denetim noktalarının ve sayısal fotoğraf sayılarının çoğaltılmasıyla dengelemedeki serbestliğin derecesi arttırılabilir (Temiz, 2011).

Işın demetleri metodu sayesinde resimler bir miktar kaydırılır ( $X_0, Y_0, Z_0$ ) ve bir miktar döndürülmektedir ( $\omega, \phi$ ).

### 3.1.5 Sayısal Ortofotoların Doğruluğuna Etki Eden Faktörler

Sayısal ortofotoların doğruluk payını belirleyen en mühim unsurlar, giren ve çıkan görüntülerinin ölçeği, iç dış yöneltme doğruluk payı, matematik modelim gerçekliğine ve görüntü eşleme doğruluğunun yanında;



- “Kullanılan kameranın niteliği ve odak uzaklığı,
- Diapozitiflerin çokluk oranı veya tarayıcı pikselindeki bitlerin niteliği,
- Tarayıcının işlem görmemiş veri tarama niteliği ve geometrik doğruluğu,
- YKN’lerin işaretleme ve koordinatlarının doğruluğu,
- Arazi yüzeyini temsil eden ürün piksellerin boyutu,
- Kontrol noktalarının seçimi,
- Ayrıca kamera kalibrasyon parametrelerinin niteliği,
- Görüntü çekiminde seçilen örtü oranı,
- Hava triyangülasyonu işleminin kalitesi,
- Kullanılan yazılımın işlem yapma kabiliyeti,
- Ortogörüntü üretiminde kullanılan sayısal yükseklik modeline bağlıdır”.

Sayısal ortofotolarda en mühim unsurlardan bir tanesi doğruluktur. Bilinen doğrulukla üretildikleri şekillerde bilinen sayısal ortofotolar, çoğunlukla sayısal ortofotolardaki karşılıklı doğruluk tam anlamıyla görüntünün ölçeğine, mutlak doğruluksa büyük kısımda yer kontrol noktalarının kalite yapısına, düşeye çevirmede kullanılacak sayısal yükseklik modelinin doğruluk ve fotoğraf ölçeğine bağlı olmaktadır (Şahin 2007).

### **3.1.6 Yer Kontrol Noktalarının ve Sayısal Yükseklik Modelinin Rolü**


Yer kontrol noktaları görüntünün alınışı sırasında algılayıcının konumunun yönlendirmesini hesaplamaktadır. Söz konusu hesaplamada uzay geriden kestirmesi ya da ışın demetleri dengelemesi gibi standart fotogrametrik algoritmalar kullanılmaktadır. Algılayıcı sistemin konumu altı adet parametreyle ifade edilmektedir. Bunlar: X, Y, Z,  $\omega$ ,  $\phi$ ,  $\kappa$ ’dir.

Yer kontrol noktaları görüntünün alım anındaki algılayıcının konumunun yöneltmesini hesaplamakta kullanılır. Hesaplamada uzay geriden kestirmesi veya ışın demetleri dengelemesi gibi standart fotogrametrik algoritmalar kullanılır. Algılayıcı sistemin konumu altı parametre ile ifade edilir: X, Y, Z,  $\omega$ ,  $\phi$ ,  $\kappa$ . Bahsedilen parametreler sayısal görüntünün her bir pikselinin yeryüzündeki tam net karşılığını bulmak için kullanılmaktadır.

Başka mühim bir konuysa yer denetim konumlarının görüntüdeki dağılımı ve dengeleme yapabilmek için gereken YKN sayısıdır. Ortofoto için gereken YKN sayısı, ortofoto piksek koordinatlarındaki hataları engellemek için çoğunlukla yer ölçmeleriyle temin edilmektedir. Ortofoto üretimi obje uzayı ve görüntü uzayı arasındaki bağlantıyı belirlemek için uzay geriden kestirme metodunu kullanmaktadır. Bu durumdan dolayı yer denetim koordinatlarının doğruluk seviyesi ortofotoların doğruluk seviyesini etkilemektedir (Şahin 2007).

Sayısal yüksekliğin modeli, sayısal biçimdeki bir alan içinde yer alan farklı noktaların yüksekliklerini ifade etmektedir. Sayısal yükseklik modeli üretebilmek için gereken veriler yer ölçmeleri, topoğrafik haritaların sayısallaştırılması, geleneksel hava fotogrametrisi, dijital fotogrametri (uzaktan algılama görüntü verileri ile), dijital kamera monte edilmiş insansız hava araçları, uydu SAR verileri gibi farklı kaynaklardan elde edilmektedir (Gupta 2017).

Sayısal yükseklik modeli, sayısal arazi üstünde yer alan orman, bina ve bitki örtüsü gibi ayrıntıları içermemektedir. Şekil 3.8'de gösterildiği üzere sayısal yükseklik modeli yansıtılmaktadır.



**Şekil 3.8** Sayısal Yükseklik Modeli.

Sayısal yükseklik modeli meydana getirmek fotogrametri çok önemli bir işlem olarak karşımıza çıkmaktadır. Sayısal yükseklik modeli tek başına bir ürün olduğu kadar ortofoto gibi malzemelerin de meydana getirilmesinde mühim bir rol oynamaktadır. Dijital fotogrametri sayısal yükseklik modellerinin otomatik bir biçimde rol olmasını sağlamaktadır. Sayısal yükseklik modelleri dijital anlamdaki nokta ve çizgilerin arazi yüzeyinin geometrik bir biçimde gösterilmesini sağlamaktadır.

Çoğunlukla sayısal yükseklik yöntemlerindeki koordinat bilgileri herhangi bir dik konum sisteminde tanımlanmış x ve y koordinatlarıyla yüzey ya da arazi yapısıya yükseklikle h ya da z ile ifade edilmektedir. Diğer bir yaklaşım modelinde arazi yüzey yapısının yine h veya z olarak koordinat bilgileri coğrafi enlem ( $\varphi$ ) ve boylam ( $\lambda$ ) ile ifade edilmektedir. Sayısal yükseklik metodunda istenen amaç ve doğruluğa uygun bir biçimde yüzey

üstünde gereken sayı ve sıklıkta konumları bilinen noktalar aracılığıyla yüzeyin matematiksel ve sayısal olarak tanımlanmasıdır (Toz 1989).

Sayısal yükseklik modeli, ortorektifikasyon işleminde arazinin neden olduğu yer değişikliklerini tamamen ortadan kaldırarak görüntüyü ortogonal bir projeksiyona çevirmektedir. Bu aşamada her eleman yüksekliklerden oluşan SYM matrisi, seçilen ortofoto matrisiyle karşılaştırılmaktadır. Herhangi bir yer örnekleme uzaklığı verilen bir ortofoto için seçilmektedir. Devam eden süreçte örnekleme aralıkları boş bir ortofoto matrisinde belli bir alanı düzgün bir grid ağına bölmekte kullanılmaktadır. Gerçekte bu aşamada bahsedilen sayısal ortofotonun niteliğidir. Pikseller boş bir ortofoto matrisine sayısal yükseklik modelinin her bir grid elemanından bir gri değeri atanarak iz düşürülmektedir.

Sayısal yükseklik modelinde doğruluk, ortofotodaki planimetrik doğruluğu etkilemiş olduğu için sayısal ortorektifikasyon işleminde mühim bir rol almaktadır. SYM'lerin doğruluğu kaynak veri ölçekleri, çözünürlük ve kalite, SYM grid aralığı ve işlem algoritmaları gibi birtakım unsurlara bağlı olarak gelişmektedir (Şahin 2007)

İncelenen bir ortofotonun doğruluğu temel olarak, SYM'nin doğruluk unsurlarına ve sonuç enterpolasyon sorunlarına bağlı olarak gelişmektedir. Bunun yanında eğer her bir ortofoto pikseli için bir SYM noktası bulunuyorsa hiçbir enterpolasyon sağlamamaktadır ve enterpolasyon sorunları bulunmamaktadır. Bu durumlarda SYM toplamak gerçekçi durmamaktadır. Gerçekte SYM için daha büyük aralıklar kullanılmaktadır (Şahin 2007)


Sayısal yükseklik modeli, dijital ortofotoya daha mühim bir bileşenini bir araya getirmektedir. Bu sayısal yükseklik modelinin uygunluğu ise aşağıda ifade edilmiştir:

- “Ortofotonun üretileceği ölçeğin özelliklerine,
- Haritalanacak yüzeyin pürüzlülüğüne,
- Hava kamerasının odak uzaklığına ve
- Büyütme gücüne bağlıdır”.

Sayısal yükseklik modelindeki noktalar arazi yüzeyinin durumunu en iyi yansıtacak şekilde sık ya da seyrek olarak üç boyutlu noktalar halinde toplanmaktadır. Nokta toplama sırasında arazide çok fazla eğim varsa daha sık veri toplanırken arazi daha düz ise seyrek noktalarda veriler toplanmalıdır. Böylece hem arazi daha iyi temsil edilir hem de sayısal yükseklik modeli ve ortofotonun doğruluk oranı yükselmiştir.

### 3.1.7 Sayısal Ortofotonun Çizgisel Haritalara Göre Avantajları

Ortofoto meydana getirirken ölçek ve doğruluğu açığa çıkartan en mühim parametre yer örnekleme aralığı (YÖA)'dır (Şekil 3.9). Bugün yapılan büyük ölçekli ortofoto meydana getirme araştırma ve çalışmalarında yer örnekleme sıklığı, 1/1000 ölçekli meydana getirimlerde 8 cm- 10 cm, 1/2000 ölçekli çalışmalarda 15 cm- 18 cm, 1/5000 ölçekli çalışmalarda da 25 cm- 30 cm arasında seçilir.



Şekil 3.9 Yer örnekleme aralığı.

Sayısal ortofotoların avantajları şu şekilde sıralanabilir;

- “Yüksek doğruluk ve veri zenginliği,
- Daha kısa sürede üretim, düşük maliyet, yüksek verimlilik,
- Üretimde ve türevi ürünlerde esneklik,
- Sayısal görüntü üzerinden bilgisayar teknolojileri ile daha fazla veri ve daha çok bilgi çıkarımı,

- Radyometrik manipülasyonlar (görüntü kalitesi, mozaikleme, renk düzenleme, dinamik aralık ayarının değiştirilmesi vs.),
- Vektör verileri ile raster verilerin entegrasyonu sağlanmaktadır”.
- “Yeryüzü üzerindeki tüm objeler ortofoto üzerinde de bulunduğundan kullanıcıya eksiksiz bilgi sunar.
- Çok sayıda taranmış ham veri depolanabilir ve hızlıca transfer edilebilir.
- Çok yakın noktalardan oluşan bir ağ ile yeryüzü temsil edildiği için geometrik doğruluk daha yüksektir.
- Sayısal ortofotolar kolaylıkla yorumlanabilir ve ucuz ve yüksek kalitede çıktılar alınabilir.
- Vektör bilgileri ek bir çalışma yapılmadan bilgisayarda eş zamanlı olarak görüntülenebilir”.
- “Dijital ortofotolar aslında üç boyutlu veri kaynaklarıdır, ancak iki boyutlu veri gibi görünmektedir. Programlarda, ortofotolar üzerinden arazideki herhangi bir detayın ya da araziye temsil eden piksellerin herhangi birisinin X Y Z koordinatları ölçülebilirken, yine programlarda sayısal vektör haritalarındaki verilerin ise sadece seçilen nokta, doğru ve alan gibi detayların sorgulanması ve X Y Z koordinatlarının alınabilmesi olanaklıdır” .
- “Sayısal ortofotoyu üretirken fotoğrafların bir bütün halinde yatay düzleme alınması önemlidir. Sayısal vektör harita üretiminde ise stereo model alanı operatör tarafından incelenerek arazi yüzeyindeki detayların yorumlanması ve ölçeğin gerektirdiği tüm nokta, çizgi ve alan kaplayan detayların herbiri birbirlerinden bağımsız olacak şekilde birer birer kıymetlendirilmesi gerekmektedir” (Özbalımcu 2007, Kraus 1997).
- “Vektör haritalarda kartografik çizim hatalarından kaçınılamazken, ortofotolarda ise sayısal veriler üzerinde çok fazla kartografik çizim ve düzeltme işlemi yapılamamaktadır.
- “Ortofoto mozaiklerini elde etmek ve geniş bir alanı tek bir ortofoto ile temsil edebilmek için çok sayıda ortofoto birleştirilebilmektedir.
- Yüzeyin üstündeki istenilen ve istenilmeyen bütün detay noktaları ve ağaçlık alanlar olduğu gibi görüntülenebilmektedir.
- Ortofotoların üzerinde her türlü üç boyutlu ölçümler (uzunluk, alan, koordinat, açı, yükseklik farkı gibi) ve çeşitli mühendislik uygulamaları (kesit çıkarma, perspektif görüntü alınması vb.) yapılabilmektedir.

### 3.1.8 Sayısal Ortofotoların Kullanım Alanları

Sayısal ortofotolar, üretimi hızlı ve maliyeti düşük olması açısından ve araziye ait tüm detayları verebilmesi, kolayca okunabilmesi açısından çoğu meslek grubu tarafından tercih edilmekte ve çok çeşitli alanlarda kullanılmaktadır. Bu kullanım alanlarından bazıları şu şekilde sıralanabilir;

- “Kentsel planlama ve uygulama çalışmalarında,
- Tarımsal faaliyetlerin planlanmasında,
- Ormancılıkta ve orman kadastrosu çalışmalarında,
- Doğal afet müdahale ve hasar tespit çalışmalarında,
- Aciliyeti olan çalışmaların altlıklarının temininde,
- Erozyona uğramış bölgelerin tespiti veya oluşabilecek erozyonları önleme çalışmalarında,
- Kadastro yenileme çalışmalarında altlık oluşturmada,
- Şehirlerin 3B modellemesinde,
- Mevcut haritaların güncelleştirme çalışmalarında” (Akdeniz 2004),
- “Şehir bölge planlama, jeoloji ve jeofizik çalışmaları, yol yapım projeleri, arazi yüzeyinin ve bitki örtüsünün yorumlaması ve uygun güzergah tespitinde,
- Yapılacak olan herhangi alt yapı ya da üst yapı çalışmalarının yaklaşık maliyetinin hesaplanması, bir proje kapsamında büyük çaplı yatırımlar yapılmadan önce ön avan projelerinin yapılmasında,
- Halihazırda var olan, çeşitli ölçeklerdeki sayısal vektör haritaların en kısa sürede güncellenmesini sağlayan harita revizyonunda yaygın olarak kullanılmaktadır” (Özbalımcu 2007).


### 3.2 Segmentasyon

Segmentasyon basit bir mantıkla, benzer nitelikleri taşıyan pikselleri gruplayıp bölme işlemidir. Bölme prosedüründe, resmin niteliklerini aşamalı olarak daha anlamlı bir şekle dönüştürmek ve bu anlamlı niteliklerle birlikte sınıflandırmayı kolaylaştırmak amaçlanmıştır. Oluşan bu bölümler görüntünün orijinal piksellerine göre objeleri daha iyi temsil ettiği için sınıflandırma işlemi basitleştirilmiş olur.

Segment tabanlı sınıflandırma, hava fotoğrafları ile elde edilmiş verilerin sınıflandırılması için oldukça uygundur ve arazideki yıllara göre ağaçlık alanlardaki değişim gibi farklılıkları gözlemlemeye olanak sağlar.


### 3.2.1 Satranç Tahtası Segmentasyonu

Satranç tahtası segmentasyonu, görüntü yalnızca kullanıcı tarafından önceden tanımlanmış boyutta kare nesnelere bölündüğünden, mevcut en basit segmentasyondur. Bölümlendirmede temel alınan veriler dikkate alınmaz. Bu nedenle, büyük nesnelere oluşturulduğunda, sınıflandırmak istediğiniz verilerdeki özellikler sınırlandırılmaz. Bu segmentasyon genellikle segmentasyonun bir sınıflandırma ile kombinasyon halinde birkaç adımda gerçekleştirildiği daha gelişmiş işlemlerde kullanılır. Örnek satranç tahtası segmentasyonu Şekil 3.10'de, kullanılan parametreler ise Şekil 3.11'de gösterilmiştir.



Şekil 3.10 Satranç Tahtası Segmentasyonu.







Şekil 3.11 Satranç Tahtası Segmentasyonu Parametreleri.

### 3.2.2 Dörtlü Ağaç Segmentasyonu

Boyutu nesne varyasyonu ile tanımlanan normal kare nesnel oluşturur. Nesnel, elde edilen nesnelere tümü izin verilen varyasyonun üst sınırı içinde oluncaya kadar daha büyük nesnel bölünerek oluşturulur. Çok çözünürlüklü segmentasyonda olduğu gibi, son bir nesnenin oluşturulduğu varyasyon bir ölçeklendirme parametresi kullanılarak tanımlanır. Örnek dörtlü ağaç segmentasyonu Şekil 3.12’de, kullanılan parametreler ise Şekil 3.13’de gösterilmiştir.



Şekil 3.12 Dörtlü Ağaç Segmentasyonu.



Şekil 3.13 Dörtlü Ağaç Segmentasyonu Parametreleri.


### 3.2.3 Kontrast Bölme Segmentasyonu

Bu algoritmanın çalışma prensibi, ortaya çıkan açık renkli nesnelere (eşiğin üstündeki piksel değerlerinden oluşan) ve koyu renkli nesnelere (eşiğin altındaki piksel değerlerinden oluşan) kullanarak kontrastı en üst düzeye çıkararak bir eşik değeri kullanarak açık ve koyu nesnelere bölmeyi amaçlar. Algoritma, operatör parametrelerinin sağladığı değerler arasındaki farklı piksel değerlerini, girilen aşama boyutuna ve aşama


parametresine göre seçilen değerleri dikkate alarak bu ayırmayı optimize etmeyi amaçlamaktadır.

### 3.2.4 Çok Çözünürlüklü Segmentasyon

Bu segmentasyon yöntemi, tekrarlamalı bir algoritma kullanarak nesnel oluşturmayı amaçlar. Bütün nesnel tek tek her pikselden başlayarak, üst nesne varyansını temsil eden bir değere varıncaya kadar gruplanır. Varyans değeri (ölçek parametresi), nesnelin benzerlik sınırlarını minimuma indirmek için şekil ve kompaktlık parametrelerini kullanarak gruplandırılır. Varyans değerini (ölçek parametresini) artırarak, daha büyük nesnel oluşturulabilir. Örnek çok çözünürlüklü segmentasyon Şekil 3.14’de, kullanılan parametreler ise Şekil 3.15’de gösterilmiştir.



Şekil 3.14 Çok Çözünürlüklü Segmentasyon.



Şekil 3.15 Çok Çözünürlüklü Segmentasyon Parametreleri.

### 3.2.4.1 Ölçek Parametresi

Kullanılan bu parametre ile ortalama segment boyutları belirlenir. Parametre değerini ne kadar büyütürsek, segmentler o kadar heterojen yani farklı nitelikleri içinde bulunduran bir grup olmuş olur. Oluşan segmentlerin niteliklerinin ayrı ayrı ve doğru olması için ölçek parametresini küçük tutmamız gerekir. Literatür taraması yaptığımızda, geçerliliği olan bir değer görülmemiştir. Her çalışmanın kendine özgü kullanması gereken bir parametre değeri vardır.

### 3.2.4.2 Şekil Parametresi


Kullanılan bu parametre ile nesnelerin renk değerleri ile nesnelerin şekilleri arasındaki tutarsızlığa etki ederek homojen segmentlerin oluşumuna katkı sağlamak amaçlanır.

### 3.2.4.3 Bütünlük Parametresi


Kullanılan bu parametre ile oluşturulmak istenen segmentlerin bütün ya da yumuşak olmasına etki etmek amaçlanmıştır.

### 3.2.5 Spektral Fark Segmentasyonu

Bu segmentasyon yöntemi, belirtilen değerin yani maksimum spektral farkın altında spektral ortalamaya sahip komşu nesnelerin, sonuç nesnelere üretmek için birleştirilmesini amaçlar. Örnek spektral fark segmentasyonu Şekil 3.16'da, kullanılan parametreler ise Şekil 3.17'de gösterilmiştir.



Şekil 3.16 Spektral Fark Segmentasyonu.



Şekil 3.17 Spektral Fark Segmentasyonu Parametreleri.

### **3.3 Sınıflandırma**

Bir görüntünün içerisinde yer alan her piksel ve objeye etiket atama işlemine sınıflandırma denilmektedir. Bu durumda objeye dayalı bir fotoğraf ya da görüntü kategorilendirmeye odaklanılarak girdi olan görüntüye Mean-Shift bölütleme metodu uygulanarak bölütler temin edilir. Her objeye dair nitelikler (spektral, dokusal ve mekansal) sınıflandırma sonuçlarından faydalanılarak meydana getirilmektedir. Son olarak, özellik seti kullanılarak kategorilendirme işlemleri oluşturulmaktadır.

Sınıflandırma yöntemleri uygulama olarak kontrollü ve kontrolsüz, yöntem olarak nesne ve obje tabanlı olarak ana hatlarıyla gruplandırılabilir.

Kontrollü sınıflandırmada operatöre ideal sınıfların nasıl oluşturulacağı sorulsa da, kontrolsüz sınıflandırmada sınıfların oluşumu operatörden muaf şekilde gerçekleşir. Nitelikleri benzerlik gösteren nesnelere, sınıf sınıf gruplara ayıran istatistiksel toplama teknikleri kullanılır.

Yapılmış olan literatür taramasında çeşitli sınıflandırıcıların kombinasyonunun kategorilendirilmesinin doğruluk payını yükseltebileceği ifade edilmektedir (Jamil ve Bayram 2017, Ghamisi vd. 2017). Her tekil kategorilendirme fonksiyonlarında özellikler iyi eğitilemeyebilir. Çeşitli kategorilendirilmelerin kombinasyonu ile beraber her kategorinin kuvvetli taraflarının güçlü kısımlarından faydalanarak kategorize edilen çıktılarının bir araya getirilmesiyle kategorilendirme işleminin doğruluğu yükseltilebilir.

#### **3.3.1 Piksel Tabanlı Sınıflandırma**


Piksel tabanlı sınıflandırma yönteminde, her bir fotoğraf piksellerinin sahip oldukları spektral nitelikleri analiz edilir. Piksel bir hava fotoğrafının uzamsal birimi olduğu için, bu bir geleneksel gruplandırma yöntemidir ve uygulanması basit bir yöntemdir.

### 3.3.2 Nesne Tabanlı Sınıflandırma

Hava fotoğraflarının analizinde uygulanan bir yöntem olan nesne tabanlı görüntü analizi, geleneksel bir yöntem olan piksel tabanlı görüntü analizine göre daha yakın zamanda geliştirilip kullanılmaya başlanmıştır. Piksel tabanlı görüntü analizi, her bir pikseldeki nitelikleri incelerken, nesne tabanlı görüntü analizi, objeler veya görüntü objeleri olarak isimlendirilen benzer nitelikleri taşıyan piksellerin oluşturduğu bir dizi veriye dayanır. Bu veriler benzerliklerine göre segmentasyon yöntemiyle gruplandırılır. Ölçek, segmentasyon yapılırken dikkat edilmesi gereken bir husustur. Sınıflandırılmak istenen objelerin büyüklüklerine göre bir ölçek belirlenerek segmentasyon işlemi yapılır. Böylece benzer nitelikleri taşıyan pikseller anlamlı objelere dönüşmüş olur. Bu anlamlı objelerin sınıflandırılması içinse çeşitli indisler kullanılır.

#### 3.3.2.1 Destek Vektör Makinası (SVM)

SVM sınıflandırma metodu komplike deseni bulunan fotoğrafların sınıflandırılmasında son derece etkili bir yöntemdir. Uzaktan algılama verilerinin kategorilendirilmesinde az sayıda eğitim verisi ile kategorilendirmenin yapılmasına imkan sunduğu için büyük eğitim grupları ile çalışılma zorunluluğunu bulunmamaktadır. Bu sebeple sık olarak kullanılan bir metod olarak karşımıza çıkmaktadır. SVM yönteminde optimize edilmiş hiper düzlemler yardımı ile iki kategorinin ayırt edilebilirliği maksimize edilmektedir. Geometrik olarak, en yakın veri noktası ve hiper düzlem arasındaki uzaklık optimum uzaklık (margin) olarak isimlendirilir. Şekil 3.18'de hiper düzlem ile destek vektörü ismi verilen veri noktası arasındaki ayırma çizgisi gösterilmiştir.  $w / \|w\|$  başlangıç ile hiper düzlem arasındaki geometrik uzaklıktır.



Şekil 3.18 SVM sınıflandırıcı için hiper düzlem gösterimi.

Olağan çözüm yaratılması için eşitlik maksimize edilmelidir. Doğrusal olarak ayrılabilir kategorilendirme sorunu için verilen kısıtlar altında genel bir olağan çözüm mümkündür. Genellikle tüm sorunlar doğrusal olarak ayrılabilir olmadığı için eşitlik ve bu tür komplike sorunların problemlerinde hiper düzlem kullanılamaz. Bunun için çözüm yolu giriş verisini çekirdek fonksiyon aracılığıyla daha üst büyüklükte bir boyuta dönüştürmektir. Bu sayede dönüştürülen veriler doğrusal olarak ayrılabilir ve SVM sınıflandırıcının verileri ayrıştırılmak için hiper düzlem oluşturulur. Eşitlikle çekirdek fonksiyonu yeniden düzenlenmelidir.

## Lineer Destek Vektör Makineleri

### Lineer Ayrılabilme Durumu

Eğitim amacıyla kullanılacak veri setinin  $N$  elemandan oluşan  $\chi = \{x_i, y_i\}, i = 1, 2, \dots, N$  olduğunu varsayalım. Burada  $y_i \in \{-1, 1\}$  etiket değerlerini ve  $x_i \in \mathbb{R}^d$  özellik vektörünü ifade etmektedir. Lineer olarak ayrılabilme durumunda ayırıcı aşırıdüzlem ile ayrılabilir. DVM, bu aşırı düzlemin örnek gruplarına eşit uzaklıkta olmasını amaçlayan bir yöntemdir (Özkan, 2008). Veri kümelerini birbirinden ayırmak için birçok aşırıdüzlem kullanılabilir. Ancak, en uygun yol iki aşırıdüzlem arasında en büyük boşluğa sahip olanları seçmektir. Örnek olarak  $H_1$  ve  $H_2$  aşırıdüzlemi göz önüne alınabilir. Bu iki aşırıdüzlemin ortasına oluşturulan  $H_0$  ise optimal ayırma düzlemi adı verilen ve iki sınıfı birbirinden ayıran doğrusal aşırıdüzlemdir. Bir aşırı düzlem üzerindeki noktalar cinsinden  $H_0$  düzlemi 3.3 numaralı denklemde gösterilmektedir.



$$H_0 = W^T X + b = 0 \quad (3.3)$$

Bu ifade 3.4 numaralı denklemde gösterildiği şekilde yazılabilir:

$$\sum_{i=1}^n w_i x_i + b = 0 \quad (3.4)$$

Burada  $W$  ağırlık vektörünü  $W = \{W_1, W_2, \dots, W_n\}$ ;  $n$  ise niteliklerin sayısını göstermektedir. İfade içinde yer alan  $b$  ise sabit bir sayıyı göstermektedir.  $S_1$  ve  $S_2$  olmak üzere iki niteliğimizin olduğunu varsayalım. Eğitim kümesi ise iki boyutlu uzay söz konusu olduğu için  $X = (x_1, x_2)$  biçimindedir. Burada  $x_1$  ve  $x_2$  değerleri  $X$  için,  $S_1$  ve  $S_2$ 'nin değerleri olarak göz önüne alınır.  $H_1$  aşırıdüzlemi 3.5 numaralı denklemde olduğu gibi ifade edilir:

$$H_1: W^T X + b = 1 \quad (3.5)$$

Aynı şekilde  $H_2$  aşırı düzlemi 3.6 numaralı denklemde olduğu gibi ifade edilir.

$$H_2: W^T X + b = 1 \quad (3.6)$$

Şekil 3.10' da belirtilen aşırı düzlemin üst tarafında kalan noktalar 3.7 numaralı denkleme göre ifade edilir:


$$W^T X + b > 0, y_1 = +1 \quad (3.7)$$

Benzer şekilde aşırı düzlemin alt kısmında kalan noktalar da 3.8 numaralı denkleme göre ifade edilir:

$$W^T X + b < 0, y_2 = -1 \quad (3.8)$$

Bu iki eşitsizlikten faydalanarak,

$Y_i (w^T x_i + b) \geq +1$  elde edilir. Bu koşulu sağlayan aşırıdüzlemin iki kümenin en yakın örneklerine olan dik uzaklıkları toplamı sınır olarak adlandırılır. Optimum aşırı düzlemi bulmak için uygun  $w$  ve  $b$ (orijine olan uzaklık) değerleri hesaplanmalıdır (Cortes 2007).



Şekil 3.19 Optimum ayırıcı yüzey.

Optimum aşırı düzlem sınırını en yüksek değere ulaşabilmesi için  $w$  değerinin minimum olması gerekir. Bu durumda en uygun aşırı düzlemin bulunması için 3.9 numaralı denklemde belirtilen kısıtlı en uygun şekle sokma probleminin çözümü gerekmektedir (Özkan 2008).

$$\min \left| \frac{1}{2} \|w\|^2 \right| \quad (3.9)$$

Bu optimizasyon probleminin sınırlamaları ise;

$y_i (w \cdot x_i + b) - 1 \geq 0$  ve  $\gamma_i \in \{1, -1\}$  şeklindedir (Vapnik 1995). Bu optimizasyon probleminin çözümü için Lagrange formülasyonu yapılır. Problemin Lagrange denklemi ise,

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N a_i y_i (w^T x_i + b) + \sum_{i=1}^N a_i \quad (3.10)$$

3.10 numaralı denklemde gösterilmiştir. (Kavzoğlu ve Çölkesen 2010). Bu eşitlikte  $\alpha_i > 0$  değerleri pozitif Lagrange çarpanları olarak adlandırılır ve Destek Vektör Makineleri'ni tanımlamaktadır. Denklemün çözümü karmaşık olduğundan dolayı ifade Karush-Kuhn-Tucker koşulları kullanılarak dual problem formuna dönüştürülür. Problemin çözümü için KKT koşulları 3.11 ve 3.12 numaralı denklemlerde verilmiştir.

$$\frac{\partial L(w_1, b, a)}{\partial w} = w = \sum_{i=1}^n x_i y_i a_i = 0 \quad (3.11)$$

$$\frac{\partial L(w_1, b, a)}{\partial w} = \sum_{i=1}^n x_i y_i a_i = 0 \quad (3.12)$$

Bu koşullar problemin Lagrange formülasyonunda yerine konacak olursa

$$L_d = \frac{1}{2} (w_T w) - w_T \sum_i y_i a_i x_i - b \sum_i y_i a_i + \sum_i a_i \quad (3.13)$$

$$= \frac{1}{2} (w_T w) + \sum_i a_i \quad (3.14)$$

$$= \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i^T x_j \quad a_i \geq \forall_i \quad (3.15)$$

Sırasıyla 3.13, 3.14 ve 3.15 numaralı denklemler elde edilir. Burada tüm eğitim örnekleri için bir Lagrange çarpanının olduğu görülmektedir. Çözümde elde edilen çarpanların büyük bir kısmı sıfır olacaktır. Geriye kalan  $\alpha_i > 0$  değerlerine sahip  $x_i$  örnekleri destek vektörleridir ve  $H_1$  veya  $H_2$  aşırıdüzlemlerinin üzerinde yer alırlar (Çölkesen 2009).

### Lineer Ayrılama Durumu

Birçok problemde olduğu gibi hava fotoğraflarının sınıflandırılmasında örneklem setinin lineer şekilde ayrıştırılması olası değildir. Bu durumda örneklem eğitim setinin bazı bölümlerinin 18 aşırı düzlemin diğer yanında kalması sorunu ile karşı karşıya kalınabilir ve problem pozitif, hataları ifade eden, yapay bir değişkenin ( $\xi_i, i = 1, 2, \dots, N$ ) optimizasyona eklenmesi ile çözülmeye çalışılır. Eşitsizlikler yapay değişken (zayıflık



$$L_p = \frac{1}{2} \|w\|^2 + C \sum_i a_i \{y_i(w^T x_i + b) - 1 + \varepsilon_i\} - \sum_i \mu_i \varepsilon_i \quad (3.19)$$

Yukarıdaki formülasyonun çözümü için KKT şartları uygulanırsa 3.20 numaralı denklem elde edilir.

$$L_d = \sum_i a_i - \frac{1}{2} \sum_{i,j} x_i^T x_j y_i y_j a_i a_j \quad (3.20)$$

3.20 numaralı denklemde  $0 < \alpha_i < C$  aralığında yer alan Lagrange çarpanlarına karşılık gelen  $x_i$  değerleri destek vektörleridir.

### **Lineer Olmayan Destek Vektör Makineleri**

Lineer olarak ayrılabilen sınıflar hipotezi pratik uygulamalar için yetersizdir. Bu sebepten ötürü örneklerin yüksek boyutlu ve doğrusal olarak ayrılacakları uzaya taşınması ve çözümün burada aranabilmesi için, farklı uzayların aralarında dönüşüm yapan çekirdek fonksiyonlarının kullanılması gerekir. Destek Vektör Makineleri  $K(x_i, x_j) = \varphi(x) \cdot \varphi(x_j)$  formülü ile gösterilen Kernel fonksiyonu kullanarak çizgiselliği bulunmayan dönüşümler yapılabilmekte ve bu sayede yüksek boyutta çizgisel ayrımına olanak sağlamaktadır. Burada  $K$  çekirdek fonksiyonunu,  $x_i$  ve  $x_j$  ise uzaydaki verileri temsil etmektedir (Çölkesen 2009).

### **Çok Sınıflı Destek Vektör Makineleri**

Şimdiye kadar değinilen konular, kategori sayısının iki olması durumunda kullanılan yöntemlerdir. Kategori sayısının ikiden fazla ise çözüm için farklı yaklaşımlara ihtiyaç duyulur.

SVM'de birden fazla kategori içerme sorununun çözüme ulaşması için iki yöntem kullanılmaktadır. Birinci yöntem, Lagrange fonksiyonunun birden fazla kategoriye uygulanabilecek hale getirilmesidir. Fakat bu yöntemin uygulamasında kategori yani sınıf sayısının artmasına paralel olarak hata oranlarının da artması söz konusu olduğu için çözüm için sıklıkla seçilen bir yöntem değildir.

Diğer bir yaklaşım ise, SVM'nin ikili kategoriler halinde sınıflandırmaları yapabileceği şekilde çalıştırılmasını sağlamaktır. Bu yaklaşımda bire karşı bir, bire karşı hepsi ve döngüsel olmayan graf gibi farklı yöntemler kullanılmaktadır (Demirci 2007).

Bire karşı bir yaklaşımında her örnek veri seti, diğer örnek veri setleri ile ayrı ayrı eğitilir. Yani K adet sınıf olması durumunda,  $K \cdot (K-1)/2$  eğitim işlemi yapılır. Bire karşı hepsi yönteminde, her bir örnek veri seti bir sınıf, geriye kalan sınıfların tamamı bir sınıf olarak kabul edilir ve eğitim bu şekilde yapılır. Böylelikle K adet sınıf olması durumunda K adet eğitim yapılmış olur.

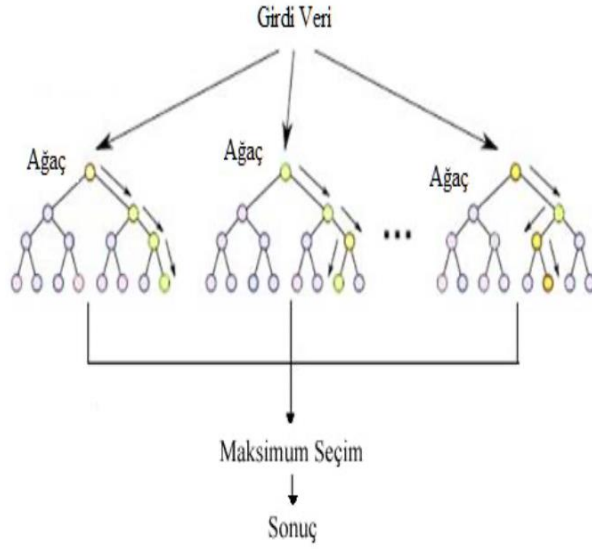
Döngüsel olmayan graf yönteminde, test aşaması dışında bire karşı bir yöntemiyle aynıdır. Eğitim bire karşı bir yöntemine göre yapılır. Test aşamasında ise, eğitim örnekleri kontrol edilmek yerine, sınıflandırılacak elemanın ait olmadığı düşünülen sınıflar elenerek işlem yapılır (Demirci 2007).

### **3.3.2.2 Karar Ağaçları**

Bu yöntem yakın zamanda radar sinyallerinin sınıflandırılmasında, karakter algılama, uzaktan algılama, uzman sistemler gibi çok geniş bir yelpazede başarılı biçimde kullanılan bir algoritmadır (Kavzoğlu ve Çölkesen 2010). Bu yöntemin yaygın olmasının en önemli nedenleri basit bir şekilde anlamlandırılabilir ve yalın olmasıdır (Safavian ve Landgrebe 1991).

Karar ağaçları eğitim verilerine bakarak test verilerinin hangi sınıfa ait olduğuna kurallar çıkararak karar vermektedir. Karar ağaçlarının temelinde sorulan sorular ve bunlara dair cevapların birleştirilmesi yatmaktadır. Bu sayede oluşan ağaç “eğer-ise ” şartlarından oluşan kurallar bütünü halini alır (Akman 2011).


Bir karar ağacı, boğum, dal ve yaprak şeklinde isimlendirilen üç ana başlıktan oluşur. Tüm özelliklerin her biri, bir boğum ile ifade edilir. Burada düğüm tarafından temsil edilmesi gereken öznitelik uydu görüntüleri için bant değeridir.



**Şekil 3.21** Örnek RF ağaç modeli.

Veri setinin katagorize etmek ve ağaç yapısını meydana getirmek amacıyla sorular sorulmaya kök boğumdan başlanır. Eğer yeni sorular sorulamıyorsa dallanma bitmiştir ve bir sınıfı temsil eden yaprağa ulaşılmıştır demektir. Şekil 3.21’de üç sınıf için dört boyutlu öznitelik değerlerinden oluşan bir karar ağacı yapısı gösterilmektedir. Şekilde  $p_i$  öznitelik değerlerini yani bant değerlerini; a, b, c, d, e, terimleri dallanma için eşik değerlerini, A, B, C ise sınıfları ifade etmektedir. Karar ağaçları oluşturulurken, kullanılan algoritmaya göre ağacın şekli değişebileceğinden, yani farklı sınıflandırma sonuçları elde edilebileceğinden kullanılacak algoritma önem taşımaktadır (Silahtaroglu 2008). Örneğin kullanacağımız yöntem CART ise, dallanma işleminde Gini indeksi ya da Twoing algoritmasının kullanımı farklı ağaç yapıları oluşmasına neden olabilmektedir.

Karar ağaçlarının oluşturulmasının ardından, bir test veri setinin sınıflandırılması işlemine kök düğümden başlayarak koşullar uygulanır ve oluşan tüm sonuçlar için ona ait uygun dal takip edilir. Buradan ya yeni koşulun uygulanacağı bir iç düğüme ya da yaprak düğüme ulaşılır ve böylelikle test verilerinin hangi sınıfa ait olduğu, hangi yaprakta sonlandığına bakılarak belirlenmiş olur. Şekil 3.22’de basit bir görüntü sınıflandırma işlemi için elde edilen karar ağacı modeli görülmektedir.



Şekil 3.22 Basit bir karar ağacı modeli.


### Karar Ağaçları Oluşturma

Sahip olduğumuz verilerden birçok farklı karar ağacı oluşturabilmemize rağmen amaç en optimum karar ağacını oluşturmaktır. Bu her zaman mümkün olmasa da yüksek bir doğruluk derecesine sahip ağacı oluşturacak birçok etkin algoritma geliştirilmiştir. Bu algoritmaların temelinde Greedy yaklaşımı bulunmaktadır. Bu yaklaşıma göre, verinin dallara ayrılabilmesi için hangi değişkenden başlanması gerektiği ve ardından oluşan alt veri grubunu tekrar alt dallara ayırmak için hangi değişkenden başlanması gerektiği ile ilgili lokal kararlar alınır. Bu algoritmaların birçoğu Hunt algoritması olarak bilinen Böl ve Elde Et (Divide and Conquer) yönteminin farklı biçimlerini kullanmaktadır.

### Böl ve Elde Et

Bu metot Hunt tarafından kullanılan, en temel ağaç yaratma algoritmasıdır. Bu yöntemin geliştirilmesine yönelik birçok çalışma yapılmıştır. Bunlardan en önemlileri, tek değişkenli karar ağaçları için Quinlan tarafından geliştirilen ID3 ve C4.5 ve çok değişkenli karar verme için Breiman'ın geliştirdiği CART algoritmalarıdır. Bu yöntemde  $K$  örnek uzay, sınıflar ise negatif ve pozitif olsun. Bu durumda Karar Ağacının oluşturulması Şekil 3.23'deki gibi olacaktır.





Şekil 3.23 Hunt Algoritması (Yıldırım 2003).

### Karar Ağaçlarının Budanması

Karar ağaçlarının üretilmesinin ardından çok geniş ve karmaşık bir görünüm ortaya çıkabilir. Eğitim verisindeki gürültü nedeniyle bir karar ağacının yaprakları tek bir sınıf verisini içerecek biçimde aşırı öğrenme (over fitting) problemiyle karşılaşılabilir. Bu halde, oluşturulan karar ağacı eğitim veri seti için mükemmel yakın sonuçlar üretirken, test veri seti için çok düşük doğruluk değeri üretebilir. Aşırı öğrenme probleminin en önemli sebepleri eğitim verisinin çok gürültülü olması ve modelin çok fazla detayı karakterize etmesidir (Akman 2011). Bu problemi çözmek için, sınıflandırma doğruluğunu etkileyemeyen kısımların çıkarılması yani bir alt ağacın çıkarılıp yerine bir yaprak yerleştirilmesi gerekir. Bu işleme karar ağacının budanması denmektedir. Bu sayede öngörülü hata oranı azaltılması ve model kalitesinin artırılması amaçlanır. Karar ağaçlarının basitleştirilmesi ve model kalitesinin artırılması için iki yaklaşım söz konusudur. Bunlar:

1. Örneklem setinin daha fazla bölünüp bölünmeyeceğine karar vermek
2. Karar ağacının kurulmasının ardından ağacın bazı bölümlerinin geriye dönük biçimde kaldırılması

İlk yöntem ön budama olarak da adlandırılır. Bölünme işlemine durdurma kriteri olarak  $\chi^2$  gibi testler yapılarak karar verilir. Bölünme işleminin sonrası ve öncesinde belirlenen limit kadar bir fark yoksa söz konusu düğüm yaprak olarak gösterilir. Bu yöntemin dezavantajı ise eşik değerin ne olacağıdır. Limit değerin çok yüksek seçilmesi durumunda, bölünme azalacağından, daha başarılı sonuçlar verecek alt bölümlere ayrılmadan işlem tamamlanacaktır (Akman 2011).

İkinci yöntemde ise, yapraklar sadece bir sınıfa ait veriyi içerdiği ana kadar dallamasına izin verilir ve karar ağacı maksimum düzeyindeyken budanır. Budama işlemi seçilen bir doğruluk(hata) ölçütüne göre yapılır. Bu yöntemin dezavantajı ise, ağacın sonradan çıkarılan kısımlarının oluşturulmasında çok fazla hesaplama yapılmasının gerekmesidir (Akman 2011).

### **3.3.2.3 Rastgele Orman (Random Forest)**

Rastgele orman önceki konularda bahsedildiği gibi bir ansambl (ensemble) öğrenme algoritmasıdır. Bu algoritmanın yine karar ağaçlarını taban alır. Tek şekilde meydana getirilen karar ağaçları tek bir bütün oluşturularak karar ormanını meydana getirirler ve ağaçların kestirimde bulunduğu veriler toplanıp son kestirim yapılır.

#### **Rastgele Orman Modelinin Kurulması**

- Orijinal veri setinden eğitim ve test verileri ayrılmasının ardından bootstrap yöntemi ile örneklemeler seçilir.
- Kullanıcı tarafından belirlenen K adet değişkenden, dallara ayrılma işlemine bilgi kazancına bakılarak karar verilir. Dallara ayrılacak değişken belirlendikten sonra, aşağı yönlü iki dal oluşturulur.
- Dallanma işlemine hangi değere göre ayrılacağına Gini indeksi kullanılarak karar verilir ve bu işlem yeni bir dal oluşturulmasına gerek kalmayana kadar devam edilir.
- Modele ait OOB hata oranı hesaplanır. Bu sayede her bir ağaca ağırlık verilmesi sağlanır.

- Sınıflama işlemi sırasında tüm ağaçlar oluşturduğu sınıflardan birine OBB ile hesaplanan ağırlıklı bir oy verir. Karar ormanı verideki her bir piksele ait, tüm ağaçların yaptığı tahminlere göre en çok oy alınan sınıf nihai sınıf olarak seçilir. Örneğin ilk sıradaki piksel için, tüm karar ağaçlarındaki ait olduğu sınıflar belirlenir. Ardından ağaçların ağırlıkları hesaplanır ve her bir sınıf için ağaçların ağırlığına göre verdiği oyların toplamı ayrı ayrı belirlenir. Piksel ağırlık toplamı en büyük olan sınıfa atanır (Akman 2011).

### **Hata Oranının Tahmin Edilmesi**

Kullanılan yöntem ne olursa olsun tüm sınıflandırma işlemlerinde amaç işlemi yüksek doğrulukla yapabilmektir. Temel hata ölçümü hata matrisinin oluşturulmasıyla hesaplanır. Rastgele orman yönteminde temel olarak iki tür hata tahmini yapılır.

### **Hold Out Yöntemi**

Bu yöntemde hata oranının hesaplanması orijinal örneklem verileri eğitim ve test şeklinde ikiye ayrılır. Genelde verinin 2/3'ü öğrenme 1/3'ü test verisi olarak ayrılırlar.

### **Çapraz Doğrulama Yöntemi**

Bu yöntemde, veri grubu eşit büyüklükte n sayıda alt veri grubuna bölünür. Bu veri gruplarından bir tanesi modeli test etmek için, geriye kalan n-1 sayıdaki veri grubu ise eğitim verisi olarak kullanılır. Her seferinde n adet veri grubundan bir tanesi test verisi olarak seçilir ve bu işlem n defa tekrarlanır. En son adımın ardından hata oranı n adet hata değerinin ortalamasının hesaplanması ile elde edilir. Çapraz doğrulama tahmini 3.21 numaralı denklemde verilmiştir.

$$CVA = \frac{1}{n} \sum_{i=1}^n A_i \quad (3.21)$$

Veri madenciliğinde genelde n değeri 10 olarak alınır (Akman 2011).

#### 4. UYGULAMA


Yöntem iş akışı şekil 4.1’de görüldüğü üzere ilk olarak İHA’lardan elde edilmiş görüntülerden ortofoto, SAM(DTM), SYM(DSM) üretilmiştir. Bu aşamada Pix4D yazılımı aracılığı ile arazide önceden tesis edilmiş YKN’leri kullanarak doğruluğu kontrol edilmiş veriler üretilirken, YKN kullanılmadığı zaman oluşan üç boyutlu modellerin doğruluğunda azalmalar olduğu gözlemlenmiştir.

Ecognition Developer yazılımında ortofoto üzerinden segmentasyon işlemi yapılmıştır. Oluşan bu segmentler üzerinden sınıflandırma yapılırken, yine eCognition Developer yazılımında üretilmiş nSYM(nDSM) ve literatür araştırması sonucu geçerliliği olduğu görülen çeşitli indeksler kullanılmıştır.

Kullanılan bu indeksler yardımıyla her bir segmente sınıflanmış ya da sınıflanmamış olarak etiketler atanmıştır. Sonuç sınıf üretildikten sonra merge(birleştir) komutu ile aynı sınıfa atanan komşu segmentler birleştirilerek veri yoğunluğu azaltılmıştır.

Sınıflandırma işlemi sona erdikten sonra ağaç sınıfını vektörel olarak export ediyoruz. ArcGIS yazılımında export edilen bu vektörel verileri smooth komutu ile yumuşatıyoruz. Piksel piksel kırıklığı olan vektörel veriler daha homojen hale gelmiş oluyor.

Sınıflandırma işleminin doğruluk oranını hesaplamak için yine Ecognition Developer yazılımında birkaç işlem adımını takip ediyoruz. Destek vektör makineleri, karar ağaçları ve rastgele karar ağacı yöntemleri ile çalışan bir makine öğrenimini sağlayan yazılım, bu öğrenim ile doğruluk analizini hesaplamamızı sağlıyor.



Şekil 4.1 İş Akış Şeması.

#### 4.1 Çalışma Alanları

Çalışmada Manisa ili sınırları içinde DJI Phantom 4 Pro cihaz ile çekilmiş 217 adet RGB bantlı fotoğraf bulunmaktadır. Fotoğraflar 100 metre yükseklikten bindirmeli olarak çekilmiş olup, üretilen ortofotonun yer örnekleme aralığı 2.68 cm çözünürlüğe sahiptir. 9 adet yer kontrol noktası kullanılmıştır.

Bir diğer bölge ise Bangkok, Tayland’da bulunan Thammasat Üniversitesi kampüsüdür. SenseFly’in sitesinden SenseFly eBee X cihazı ile çekilmiş 443 adet RGB bantlı fotoğraf kullanılmıştır. Fotoğraflar 215 metre yükseklikten bindirmeli olarak çekilmiş olup, üretilen ortofotonun yer örnekleme aralığı 6.04 cm çözünürlüğe sahiptir.


Tezin bu kısmından sonra Manisa ilindeki veriler Test Alanı 1, Thammasat Üniversitesi Kampüsündeki veriler Test Alanı 2 olarak bahsedilecektir.

#### 4.2 Görüntülerden Ortofoto, SAM, SYM Üretilmesi


Pix4D yazılımında fotoğrafların değerlendirilmesi yapıp fotoğraflardan sayısal arazi modeli, sayısal yükseklik modeli ve ortofoto üretilmiştir. Test alanı 1 için YKN'ler yardımıyla dengeleme yapılmıştır. Kullanılan YKN'lerin arazideki dağılımı Şekil 4.2'de gösterilmiştir. Test alanı 1'in; sayısal yüzey modeli Şekil 4.3'de, sayısal arazi modeli Şekil 4.4'de, ortofotosu Şekil 4.5'de gösterilmiştir. Test alanı 2'nin; sayısal yüzey modeli Şekil 4.6'da, sayısal arazi modeli Şekil 4.7'de, ortofotosu Şekil 4.8'de gösterilmiştir.



Şekil 4.2 Test Alanı 1 için YKN'lerin arazi üzerindeki dağılımı.



Şekil 4.3 Test Alanı 1 için Sayısal Yüzey Modeli.




Şekil 4.4 Test Alanı 1 için Sayısal Arazi Modeli.






Şekil 4.5 Test Alanı 1 için Ortofoto.



Şekil 4.6 Test Alanı 2 için Sayısal Yüzey Modeli.



Şekil 4.7 Test Alanı 2 için Sayısal Arazi Modeli.

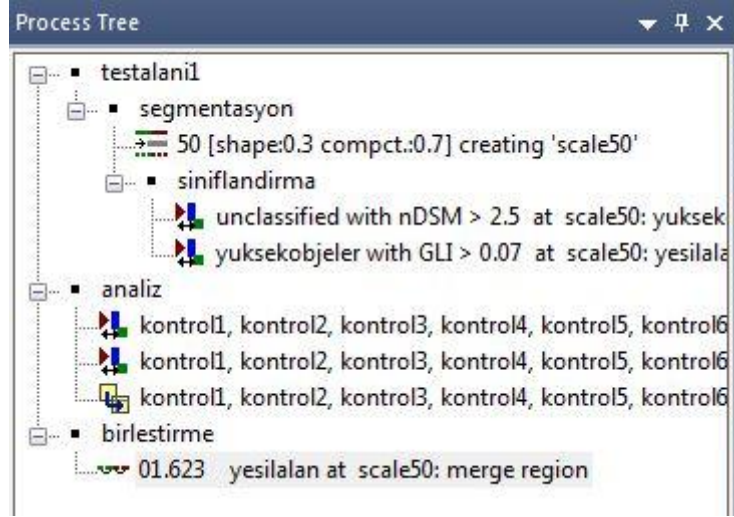


Şekil 4.8 Test Alanı 2 için Ortofoto.


### 4.3 Ağaç Tespiti

Bu aşamada Ecognition Developer yazılımına geçilmiştir. Pix4D yazılımında elde edilen SYM(DTM), SAM(DSM) ve ortofoto, programa import edilip, bu raster verilerin ilgili katmanları isimlendirilmiştir.

Create new Arithmetic Feature (Yeni aritmetik özellik oluştur) komutu kullanılarak normalize edilmiş sayısal arazi modeli oluşturulmuştur. Arazi üzerindeki detaylar düz bir düzlem üzerine matematiksel olarak aktarılmış olup, oluşan nSYM ve yine aynı komut kullanarak literatür araştırması sonucu kabul görmüş indisler girilerek segmentasyon aşamasına geçilir. Oluşan segmentler arasından istenilen özneliğe sahip olanlar sınıflandırılmıştır. Sınıflandırma işlemini doğruluk analizi, istenilen sınıftaki segmentlerin birleştirilmesi ve export işlemi takip etmektedir. Test alanları için işlem adımları Şekil 4.9 ve Şekil 4.10’de verilmiştir.




Şekil 4.9 Test Alanı 1 için İşlem Adımları.




Şekil 4.10 Test Alanı 2 için İşlem Adımları.

### 4.3.1 Segmentasyon İşlemi

Yazılımdaki beş farklı segmentasyon yöntemi denenmiş olup, nitelik olarak birbirine benzerliği bulunan piksellerin gruplandırılması açısından en uygun yöntem olarak çok çözünürlüklü segmentasyon belirlenmiştir. Çok çözünürlüklü segmentasyon yapılırken literatür araştırması sonucu şekil ve bütünlük parametrelerinin toplamının 1 i verdiği ve şekil parametresinin 0.3, bütünlük parametresinin 0.7 olarak kullanıldığı görülmüştür. Fakat şekil parametresinde genel geçerliliği olan bir değer bulunmadığı için deneme yanılma yöntemi ile uygun ölçek parametresi seçilmiştir. Farklı değerlerdeki ölçek parametresi karşılaştırması şekil 4.11 ve şekil 4.12’ de verilmiştir.




Şekil 4.11 Test Alanı 1 için Ölçek Parametresi Karşılaştırması.



Şekil 4.12 Test Alanı 2 için Ölçek Parametresi Karşılaştırması.

### 4.3.2 Segmentlerin Sınıflandırılması

Objeye tabanlı olarak oluşan segmentleri “assing class” komutu ile sınıflandırma aşamasında oluşan normalize edilmiş sayısal arazi modelini kullanarak düzlem segmentleri ve yüksek objeler olarak ayırmıştır. Test alanı 1 için nSAM değeri 2.5, test alanı için nSAM değeri 2 olarak kullanılmıştır. Şekil 4.13’de yüksek objeler sınıfına atanmış segmentler gösterilmektedir.




Şekil 4.13 Test Alanlarında Yüksek Objelerin Sınıflandırılması.

Sınıflandırılan bu segmentlerin içinden ağaçlık alanları çıkartabilmek için literatür taraması sonucu kırmızı, yeşil, mavi bantlı görüntüler için kullanılan indisler deneme yanılma yöntemi ile test edilmiştir. İndisler Çizelge 3.1’de verilmektedir. Bu indislerden çalışmaya en uygun olanı GLI (yeşil yaprak indeksi) olarak seçilmiştir. Segment özelliklerine bakarak her iki test alanı için de farklı değerler belirlenmiş olup test alanı 1 için GLI değeri  $GLI > 0.07$ , test alanı 2 için GLI değeri  $GLI > 0.1$  olarak belirlenmiştir. Test alanı 1 için GLI değerine göre sınıflandırma sonucu ağaçlık alanlar diğer yüksek objelerden ve gölgelik alanlardan ayrılmış olup, test alanı 2 de ekstra olarak gölgelik alanları ayırmak için YBO (yeşil bant oranı) indisi kullanılmıştır. Test alanı 2 için YBO değeri  $YBO < 0.4$  olarak belirlenmiştir. Sınıflandırma sonuçları Şekil 4.14’de verilmiştir.

**Çizelge 4.1** Kırmızı Yeşil Mavi Bantlı Görüntüler İçin Kullanılan İndisler.

<b>Bant İndisi</b>	<b>Formül</b>
Ortalama Bantlar Oranı (OBO)	$\frac{Kırmızı + Mavi + Yeşil}{3}$
Kırmızı Yeşil Bant Farkı (K-Y)	Kırmızı - Yeşil
Excess Green Index (EGI)	$(2 \times Yeşil) - Mavi - Kırmızı$
Yeşil Yaprak İndeksi (GLI)	$(2 \times Yeşil) + Mavi + Kırmızı$
Üçgensel Yeşillik İndeksi (TGI)	$Yeşil - (0.39 \times Kırmızı - 0.69 \times Mavi)$
Yeşil Bant Oranı (YBO)	$\frac{Yeşil}{Mavi + Kırmızı + Yeşil}$
Mavi Bant Oranı (MBO)	$\frac{Mavi}{Mavi + Kırmızı + Yeşil}$
Normalize Edilmiş Akuatik Bitki Endeksi (NRAVI)	$\frac{Yeşil - Kırmızı}{Yeşil + Kırmızı}$
Görünür Bölge Atmosferik Dayanıklılık İndeksi (VARI)	$\frac{Yeşil - Kırmızı}{Mavi + Yeşil + Kırmızı}$
Excess Red Vegetation Index (ER)	$(1.4 \times Kırmızı) - Yeşil$



**Şekil 4.14** Test Alanlarında Sınıflandırma Sonuçları.

Oluşan segmentleri komşuluğu bulunan ve aynı sınıfta olacak şekilde tek bir segment olarak birleştirme işlemi yapılmıştır. Böylece veri yoğunluğu azaltılarak export edilmiştir. Ağaçlık sınıfların ortofoto üzerinde gösterimi test alanı 1 için Şekil 4.15’de, test alanı 2 için Şekil 4.16’da verilmiştir.



Şekil 4.15 Test Alanı 1 için Sınıflandırma Sonucu.





Şekil 4.16 Test Alanı 2 için Sınıflandırma Sonucu.

## 5. BULGULAR


### 5.1 Doğruluk Analizi

Doğruluk analizi, sınıflandırma sonucunda elde edilen verilerin referans olarak kabul edilmiş olan veriler ile istatistiksel olarak karşılaştırılmasını esas alan bir doğruluk kontrol etme yöntemidir. Yapılan bu istatistiksel analizler sonucunda elde edilen hata matrisi ile sınıflandırma sonucunun sağlıklı olup olmadığı anlaşılmaktadır. Hata matrisi, 0 ile 1 arasında değişiklik gösteren kappa katsayısı ile istatistiksel olarak analiz edilir.

#### 5.1.1 Kontrol Verisinin Üretilmesi

Yapılan sınıflandırmanın doğruluk oranını hesaplamak için eCognition Developer yazılımının hata matrisi ile yaptığı doğruluk değerlendirmesi kullanılmıştır. Yazılım altıncı bölümde bahsedilen destek vektör makineleri ve karar ağaçlarının matematiksel modelini kullanarak eğitim verisi üretmektedir. Bu çalışmada eğitim verisi üretim yöntemi olarak destek vektör makineleri seçilmiştir. Kullanılan parametreler Şekil 5.1’de gösterilmiştir.

Yazılımda yeşil alan sınıfında bulunan segmentlerden on tanesi ayrı ayrı kontrol1, kontrol2, kontrol3, kontrol4, kontrol5, kontrol6, kontrol7, kontrol8, kontrol9 ve kontrol10 sınıfına manuel olarak atanmıştır. Literatürde kontrol sınıf sayıları beş ile on arasında değişmektedir. Atanan sınıflardan sonra “classifier” komutu ile kontrol sınıfındaki segmentler test alanı 1 için normalize edilmiş sayısal arazi modeli ve yeşil yaprak indeksi, test alanı 2 için ekstra olarak yeşil bant oranı değerlerine göre makine öğrenmesine tabii tutulup bir kontrol verisi üretilmiştir. Üretilen bu veri yine “classifier” komut ile “apply” seçeneği seçilerek her sınıfa uygulanmıştır. Daha sonra “classified image objects to samples” komutu ile bu sınıflar örneklem kategorisine atanmıştır.



Şekil 5.1 Destek Vektör Makineleri ile Üretilen Kontrol Verisi.

### 5.1.2 Hata Matrisi ile Doğruluk Değerlendirmesi

Karışıklık matrisi olarak da bilinen hata matrisi, test verisi kategorisindeki model ile doğruluk analizi yapmak için sıklıkla kullanılan bir yöntemdir. Bu matristen doğruluğu şu şekilde öğrenebiliriz; iki olası görülen sınıf vardır. Bunlar evet ve hayırdır. Örneğin, bir çalışma sahasında ağaçlık alanların varlığını tahmin ediyorduk, “evet”, yani çalışma sahasında ağaçlık alanların var olduğu anlamına gelirdi ve “hayır” çalışma sahasında ağaçlık alanların var olmadığı anlamına gelirdi. Örnek bir hata matrisi (Çizelge 5.1) ile açıklayacak olursak;

**Çizelge 5.1** Örnek Hata Matrisi.

	<b>Tahmin: Hayır</b>	<b>Tahmin: Evet</b>
<b>Gerçekte: Hayır</b>	50	10
<b>Gerçekte: Evet</b>	5	110

Sınıflandırma algoritmasınının 165 hektar üzerinden tahmin yaptığını varsayılacak olursa, örneğin yazılım 110 kez evet, 55 kez hayır yanıtını öngördü. Yani 110 hektarlık ağaçlık alan, 55 hektarlık ağaçlık olmayan alanı öngördü. Gerçekte ise çalışma alanında 105 hektar ağaçlık alan, 60 hektar diğer detaylar ve boş arazinin varlığını kabul edelim.

Değerler üzerinden hata matrisi ile ilgili en temel terimleri tanımlayacak olursak, Doğru Pozitifler (TP): “Evet” gerçekte ağaçlık alanlardır ve bizim de ağaçlık alan olarak tahmin ettiğimiz durumlardır.

Doğru Negatifler (TN): “Hayır” gerçekte ağaçlık olmayan alanlardır ve bizim de ağaçlık olmayan alan olarak tahmin ettiğimiz durumlardır.

Yanlış Pozitifler (FP): “Evet”i tahmin ettik yani ağaçlık alan olarak öngördük fakat gerçekte ağaçlık olmayan alanlardır.

Yanlış Negatifler (FN): “Hayır”ı tahmin ettik yani ağaçlık olmayan alan olarak öngördük fakat gerçekte ağaçlık olan alanlardır.

**Çizelge 5.2** İkili Sınıflandırıcı İçin Örnek Hata Matrisi.

	<b>Tahmin: Hayır</b>	<b>Tahmin: Evet</b>	
<b>Gerçekte: Hayır</b>	TN: 50	FP: 10	60
<b>Gerçekte: Evet</b>	FN: 5	TP: 100	105
	55	110	

Bu ikili sınıflandırıcı için oluşan matristen hesaplanan oranlar şu şekildedir;

Doğru Sınıflandırma Oranı:  $(TP+TN) / \text{toplam arazi} = (100+50) / 165 = 0.91$

Yanlış Sınıflandırma Oranı:  $(FP+FN) / \text{toplam arazi} = (10+5) / 165 = 0.09$

Doğru Pozitif Oranı:  $TP / \text{gerçekteki ağaçlık alan} = 100 / 105 = 0.95$

Yanlış Pozitif Oranı:  $FP / \text{gerçekteki ağaçlık olmayan alanlar} = 10 / 60 = 0.17$

Doğru Negatif Oranı:  $TN / \text{gerçekteki ağaçlık olmayan alanlar} = 50 / 60 = 0.83$


Yapılan doğruluk analizi ile sınıflandırma arasındaki uyumu ölçmek için Kappa katsayısı kullanılır. Yazılımda “Global Kappa Index of Agreement” olarak geçen bu katsayısı 5.1 numaralı denklemde gösterildiği gibi tanımlanır.

$$K = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i G_i)}{N^2 - \sum_{i=1}^n (G_i G_i)} \quad (5.1)$$

Formülde kullanılan değerler hakkında bilgi verecek olursak;

- $i$  : sınıf numarasıdır
- $N$  : doğruluk değerlerine kıyasla toplam sınıflandırılmış değer sayısıdır
- $m_{i,i}$  : sınıf  $i$  olarak da sınıflandırılan doğruluk sınıf  $i$ 'ye ait değerlerin sayısıdır (yani, karışıklık matrisinin diyagonalinde bulunan değerler)
- $C_i$  :  $i$  Sınıfa ait tahmini toplam değer sayısıdır
- $G_i$  :  $i$  sınıfına ait toplam doğruluk değeri sayısıdır

Yazılımda araçlar sekmesinden “accuracy assessment” komutuna girerek, istatistik türü olarak “Error Matrix Based on Samples(Örneklere Dayalı Hata Matrisi)” seçilmiştir. Yazılımdaki örnek seçim ekranı Şekil 5.2’de gösterilmiştir.



Şekil 5.2 Doğruluk Değerlendirmesi Komutu.

Test alanı 1 için oluşan doğruluk değerlendirme tablosu Çizelge 5.3’de verilmiştir.

Çizelge 5.3 Test Alanı 1 için Oluşan Doğruluk Değerlendirmesi Tablosu.

User Class	kontrol 1	kontrol 2	kontrol 3	kontrol 4	kontrol 5	kontrol 6	kontrol 7	kontrol 8	kontrol 9	kontrol10	Sum
kontrol1	92	2	2	1	5	3	5	2	6	2	120
kontrol2	0	32	0	0	0	0	5	0	0	0	37
kontrol3	2	2	78	8	7	0	0	4	2	1	104
kontrol4	0	0	5	53	0	3	0	0	0	0	61
kontrol5	0	1	2	0	87	8	4	0	0	0	102
kontrol6	0	0	0	0	0	41	0	0	0	6	47
kontrol7	0	4	0	0	0	0	89	8	0	1	102
kontrol8	0	0	4	0	0	0	0	91	0	2	97
kontrol9	0	0	5	0	0	0	0	0	78	0	83
kontrol10	0	0	0	0	0	0	3	0	0	86	89
unclassified	0	0	0	0	0	0	0	0	0	0	0
Sum	94	41	96	62	99	55	106	105	86	98	
Producer	0.9787	0.7805	0.8125	0.8548	0.8788	0.7455	0.8396	0.8667	0.907	0.87755	
User	0.7667	0.8649	0.75	0.8689	0.8529	0.8723	0.8726	0.9381	0.9400	0.96629	
Overall											
Accuracy	0.8634										
KIA	0.7916										

Oluşan bu hata matrisi sonucu test alanı 1 için;

Genel doğruluk= 0.8634= %86

Genel KIA= 0.7916= %79

Olarak hesaplanmıştır.

Test alanı 1 için oluşan doğruluk değerlendirmesi tablosu Çizelge 5.4’de verilmiştir.

**Çizelge 5.4** Test Alanı 2 için Oluşan Doğruluk Değerlendirmesi Tablosu.

User Class \ Sample	kontrol 1	kontrol 2	kontrol 3	kontrol 4	kontrol 5	kontrol 6	kontrol 7	kontrol 8	kontrol 9	kontrol10	Sum
kontrol1	87	3	4	2	0	4	3	0	2	0	105
kontrol2	4	28	1	0	0	2	5	0	2	0	42
kontrol3	1	2	74	7	0	7	2	4	4	0	101
kontrol4	3	0	0	56	3	2	1	0	3	0	68
kontrol5	5	1	1	0	81	1	4	6	0	0	99
kontrol6	1	0	0	0	0	46	0	4	0	8	59
kontrol7	0	4	0	2	2	0	93	8	0	4	113
kontrol8	1	5	2	0	0	3	8	137	0	3	160
kontrol9	0	5	3	3	4	0	7	8	51	0	81
kontrol10	0	6	2	4	3	3	6	3	2	91	120
unclassified	0	0	0	0	0	0	0	0	0	0	0
Sum	102	56	87	73	93	68	129	170	64	106	
Producer	0.8529	0.5	0.8506	0.7671	0.8710	0.6765	0.7209	0.8059	0.7612	0.85849	
User	0.8286	0.6667	0.7327	0.8235	0.8182	0.7797	0.8230	0.8563	0.6296	0.75833	
Overall Accuracy	0.7848										
KIA	0.8248										

Oluşan bu hata matrisi sonucu test alanı 2 için;

Genel doğruluk= 0.7848= %79

Genel KIA= 0.8248= %83

Olarak hesaplanmıştır.

## 6. SONUÇ

Konuların ve yapılacak çalışmaların kategorisinin değişimiyle kullanılan yöntem, metod ve ekipmanların nasıl değiştiği görülmesinin yanında hava fotoğrafçılığının bir sektör haline gelişi dikkat çekilmesi gereken bir husustur. Gerek uçak ve çeşitli hava araçları üretilmiş, geliştirilmiş ya da değiştirilmiştir. Bu yeni yöntem ile birçok projeye altlık sunan haritacılığın, veri toplamadaki çabukluğuna dikkat çekilmiştir. Günümüzde ise veri olarak sıkıntı olmamakla birlikte, bu verilerin işleme süreçleri ile alakalı sorunlar ortaya çıkmış, çalışmamızda bu sorunların çözümüne yönelik veri işleme metotlarına değinilmiştir. Çalışmanın sonucunda sıra sıra şu sonuçlara varılmıştır;

İnsansız hava aracı ile üretilen sayısal haritalar ve üç boyutlu modeller için yer kontrol noktaları büyük önem arz etmektedir. Konum doğruluğunu sağlayan yer kontrol noktaları kullanılmadığı zaman üç boyutlu modelde de deformasyon oranlarının çok olduğu görülmüştür.

Segmentasyon, veri işleme konusunda kullanıcıyı oldukça rahatlatan bir işlem olmakla birlikte, segmentasyon çeşitleri arasından en homojen sonuçları veren yöntemin çok çözümlü segmentasyon olduğu görülmüştür.

Nesne tabanlı sınıflandırma oldukça eski bir yöntem olan piksel tabanlı sınıflandırmaya göre veriyi daha hızlı işleyip, daha doğru sonuçlar vermektedir. Kullanılan parametreler ve değerler her çalışma alanı için farklı seçilip, farklı sonuçlar verebilmektedir.

Bu çalışmada uygulanan yöntem ile sık ağaçlık alanların olduğu alanlarda yani ormanlık alanlarda da ağaçlık alanların tespitinin başarılı bir şekilde gerçekleştiği görülmüştür.

Dolayısıyla her bir metrekaresi önem arz eden ağaçların tespiti başarılı bir şekilde sağlanmış olup, elde edilen bu verilerle farklı analizlere olanak sağlanmıştır.



## 7. KAYNAKLAR

- Abd-Elmotaal H, 2004, The AFH04 Digital Height Models for Africa, In IAG International Symposium on Gravity, Geoid and Space Missions" GGSM2004", Porto, Portugal.
- Akman M, 2011, Random Forests Yöntemi ve Sağlık Alanında Bir Uygulama, Türkiye Klinikleri Journal of Bio Statistik, 3, 36-48.
- Arslanbek L, 2009, Farklı Kaynaklardan Elde Edilen Sayısal Yükseklik Modellerinin Ortofoto Doğruluğuna Etkilerinin Araştırılması, Yüksek Lisans Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, 149s, Afyonkarahisar.
- Breiman L, 2001, Random Forests Machine Learning, Kluwer academic publishers, Netherlands.
- Cortes E A, Martinez M G, Rubio, N. G, 2007, Multiclass corporate failure prediction by Adaboost, International Advances in Economic Research, 13, 301-312.
- Çölkesen İ, 2009, Uzaktan Algılamada İleri Sınıflandırma Tekniklerinin Karşılaştırılması ve Analizi, Y. Lisans Tezi, Gebze Teknik Üniversitesi, Gebze Yüksek Teknoloji Enstitüsü, 153s, Gebze.
- Çölkesen İ, Yomralıoğlu T, Kavzoğlu T, 2015, Obje Tabanlı Sınıflandırmada Bölgeleme Esasına Dayalı Ölçek Parametresi Tespiti: Worldview-2 Uydu Görüntüsü Örneği, Harita Dergisi, 154, 9-18.
- Demirci D A, 2007, Destek Vektör Makineleri ile Karakter Tanıma, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 53s, İstanbul.
- Gaydos L, Ladner L, Champion R, Hooper D 1986, The Production of Orthophotographs By Digital Image Processing Techniques, aspg, 4, 241-249.
- Ghamisi P, Plaza J, Chen Y, Li J, Plaza A J, 2017, Advanced Spectral Classifiers for Hyperspectral Images: A Review, IEEE Geoscience and Remote Sensing Magazine, 5, 8-32.

- Gu Y, Liu T, Jia X, Benediktsson J A, Chanussot J, 2016, Nonlinear Multiple Kernel Learning With Multiple-Structure-Element Extended Morphological Profiles for Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 54, 3235-3247.
- Gupta N, Bhadauria H. S, 2014, Object Based Information Extraction From High Resolution Satellite Imagery Using eCognition, International Journal of Computer Science Issues (IJCSI), 11, 139.
- Hellesen T, Matikainen L, 2013, An Object-Based Approach for Mapping Shrub and Tree Cover on Grassland Habitats By Use Of Lidar And CIR Orthoimages, Remote Sensing, 5, 558-583.
- Jacobsen K, 2000, Potential And Limitation of Direct Sensor Orientation, International Archives of Photogrammetry and Remote Sensing, Vol. XXXIII, Part B3, Amsterdam, 429-435.
- Jamil A, Bayram B, 2017, Tree Species Extraction and Land Use/Cover Classification From High-Resolution Digital Orthophoto Maps, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11, 89-94.
- Jia Y, 2015, Object-Based Land Cover Classification With Orthophoto and Lidar Data, Master Tesis, School Of Architecture And The Build Enviroment, Royal institute of Technology, 75p, Stockholm.
- Kalkan K, Maktav D, 2010, Nesne Tabanlı ve Piksel Tabanlı Sınıflandırma Yöntemlerinin Karşılaştırılması (Ikonos Örneği), Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Sempozyumu, Gebze, 15-160.
- Kamps M, Bouten W, Seijmonsbergen A, 2017, Lidar and Orthophoto Synergy to Optimize Object-Based Landscape Change: Analysis Of An Active Landslide, Remote Sensing, 9, 805.
- Kavzoğlu T, Çölkesen İ, 2010, Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, Harita Dergisi, 144, 73-82.

- Keating T J, Boston D R, 1979, Digital Orthophoto Production Using Scanning Microdensitometers, *Photogrammetric Engineering and Remote Sensing*, 45, 735-740.
- Korsgaard N J, Nuth C, Khan S A, Kjeldsen K K, Bjørk A A, Schomacker A, Kjær K H, 2016, Digital Elevation Model and Orthophotographs of Greenland Based on Aerial Photographs From 1978–1987, *Scientific Data*, 3, 160032.
- Kraus K, 1997, *Photogrammetry*, Dummlers Verlag, 2, 95-98.
- Kraus K and Waldhausl P, 1993, *Photogrammetry*, Dommler, 397p, Ferd.
- Li C, Shao G, 2012, Object-Oriented Classification of Land Use/Cover Using Digital Aerial Orthophotography, *International journal of remote sensing*, 33, 922-938.
- Özbalımcu M, 2007, Fundamentals of Orthophoto Map Production By Photogrammetric Method, Advantages And Applications of Orthophoto, Turkey National Photogrammetry and Remote Sensing Society IV. Technical Symposium, İstanbul, Reported Book, 1-11.
- Özkan Y, 2008, Veri Madenciliği Yöntemleri, Papatya Yayıncılık Eğitim, 216s, İstanbul.
- Quinlan J R, 1993, C4. 5: Programs for and Neural Networks. *Machine Learning*, Morgan Kaufman Publisher, 270p, California.
- Sabuncu A, Sunar F, 2017, Ortofotolar ile Nesne Tabanlı Görüntü Sınıflandırma Uygulaması: Van-Erciş Depremi Örneği, *Doğal Afetler ve Çevre Dergisi*, 3, 1-8.
- Safavian S R, Landgrebe D, 1991, A Survey of Decision Tree Classifier Methodology, *IEEE transactions on systems, man, and cybernetics*, 21, 660-674.
- Safavian S R, Landgrebe D, 1991, A Survey of Decision Tree Classifier Methodology, *IEEE transactions on systems and cybernetics*, 21, 660-674.
- Sesören A, 2006, Fotojeoloji, Derin Yayıncılık, 103s, İstanbul.
- Silahtaroğlu G, 2008, Kavram ve Algoritmalarıyla Temel Veri Madenciliği, 1. Baskı,

Papatya Yayıncılık, 104s, İstanbul.

Şahin,İ, 2007, Farklı Kaynaklardan Elde Edilen Sayısal Yükseklik Modellerinin Ortofoto Doğruluğuna Etkilerinin Araştırılması, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, 142 s, Selçuk Üniversitesi, Konya.

Toz F G, 1989, Sayısal Arazi Modelleri, İTÜ Dergisi, 47, 2.

Tufan T, 2012, Ortofoto Harita Üretimi ve Coğrafi Bilgi Sisteminde Veri Kaynağı Olarak Kullanımının Araştırılması, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 137s, Konya.

Vapnik V N, 1995, The Nature of Statistical Learning Theory, New, Springer Verlag, 299p, New York.

Yastıklı N, 2004, Algılama Sistemlerinin Doğrudan Yöneltilmesi, HKM Jeodezi, Jeoinformasyon ve Arazi Yönetimi Dergisi, 90, 5-11.

Yıldırım S, 2003, Tümevarım Öğrenme Tekniklerinden C4. 5'in İncelenmesi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 79s, İstanbul.

Yılmaz A, 2002, Farklı Kaynaklardan Üretilen Sayısal Yükseklik Modellerinin Doğruluk Araştırması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 81s, İstanbul.

### **İnternet Kaynakları**

1- [https://webdosya.csb.gov.tr/db/cbs/editordosya/TUCBS\\_KavramsalModel1\\_1.pdf](https://webdosya.csb.gov.tr/db/cbs/editordosya/TUCBS_KavramsalModel1_1.pdf), 03.03.2020

2-<https://s3.eu-central-1.amazonaws.com/senseflycom/datasets/thammasat-university/RGB-img.zip>, 03.03.2020

## ÖZGEÇMİŞ

Adı Soyadı : Muharrem Cihan CEYLAN  
Doğum Yeri ve Tarihi : Tavşanlı / KÜTAHYA 14.07.1991  
Yabancı Dili : İngilizce  
İletişim (Telefon / e-posta) : m.cihanceylan43@gmail.com

### Eğitim Durumu (Kurum ve Yıl)

Lise : Tavşanlı Anadolu Lisesi (2006 –2010)  
Lisans : Yıldız Teknik Üniversitesi, Harita Müh. Bölümü (2010–2014)  
Yüksek Lisans : Afyon Kocatepe Üniversitesi, Fen Bilimleri Ens., Harita  
Mühendisliği ABD, (2017 –2020)

### Yayımları (SCI ve diğer) :

**Ceylan M C**, Uysal M, İnsansız Hava Araçlarından Üretilen Verilerin Değerlendirilmesi ve Ağaçlık Alanların Sınıflandırılması. Türkiye İnsansız Hava Araçları Dergisi, 1, 1-6.