

T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MULTİSPEKTRAL İHA VERİLERİNİN OBJE TABANLI  
SINIFLANDIRILMASINDA NDYM TABANLI PERFORMANS  
ARTIRIM YAKLAŞIMLARI

İLYAS AYDIN

YÜKSEK LİSANS TEZİ  
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI  
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ PROGRAMI

DANIŞMAN: PROF. DR. UMUT GÜNEŞ SEFERCİK

OCAK 2024

**T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MULTİSPEKTRAL İHA VERİLERİNİN OBJE TABANLI  
SINIFLANDIRILMASINDA NDYM TABANLI  
PERFORMANS ARTIRIM YAKLAŞIMLARI**

**İLYAS AYDIN**

**YÜKSEK LİSANS TEZİ  
HARİTA MÜHENDİSLİĞİ ANABİLİM DALI  
JEODEZİ VE COĞRAFİ BİLGİ TEKNOLOJİLERİ  
PROGRAMI**

**DANIŞMAN: PROF. DR. Umut GÜNEŞ SEFERCİK**

**OCAK 2024**

**T.R.**  
**GEBZE TECHNICAL UNIVERSITY**  
**GRADUATE SCHOOL**

**NDSM-BASED POTENTIAL ENHANCEMENT  
APPROACHES IN OBJECT-BASED CLASSIFICATION  
OF MULTISPECTRAL UAV DATA**

**İLYAS AYDIN**

**A THESIS OF MASTER OF SCIENCE  
DEPARTMENT OF GEOMATICS ENGINEERING  
GEODESY AND GEOGRAPHICAL INFORMATION  
TECHNOLOGIES PROGRAM**

**ADVISOR: PROF. DR. UMUT GÜNEŞ SEFERCİK**

**JANUARY 2024**

## YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun 27/12/2023 tarih ve 2023/27 sayılı kararıyla oluşturulan jüri tarafından 10/01/2024 tarihinde tez savunma sınavı yapılan İlyas AYDIN'ın tez çalışması Harita Mühendisliği Anabilim Dalında Jeodezi ve Coğrafi Bilgi Teknolojileri Programında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

### JÜRİ

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Umut Güneş SEFERCİK

ÜYE

: Prof. Dr. Taşkın KAVZOĞLU

ÜYE

: Prof. Dr. Fevzi KARSLI

### ONAY

Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Yönetim Kurulunun

...../...../..... tarih ve ...../..... sayılı kararı.

İMZA/MÜHÜR



*Eşim Nur, Kardeşim Umut*

*ve*

*Tüm Ailem'e*

## ÖZET

Endüstri 4.0 devrimiyle birlikte, dijitalleşme ivmesi hızla artan dünyada, akıllı teknolojiler gün geçtikçe daha çok önem kazanmakta ve kullanımları giderek yaygınlaşmaktadır. Dijitalleşme temelinde ortaya çıkan gelişim sürecinde, haritacılık veri ve teknolojileri, uygulamaların kalbinde yer alan en önemli araçlardandır. Uydu ve hava kaynaklı haritacılık teknolojileri, yersel teknolojilere kıyasla çok daha geniş alanlarda dijital veriye daha hızlı bir şekilde ulaşımı sağlamakta, üstelik bu verilerin istenen periyotlarda tekrarlı şekilde elde edilmesini olası kılmaktadır. Sensör teknolojilerinin gelişimiyle birlikte, yüksek mekansal çözünürlüklü veriler ulaşılabilir hale gelmiş ve bu kavram önemini kaybederken, zengin bilgi içeriğine sahip görüntülerin yer aldığı sınıflandırma problemlerinin doğruluğu önem kazanmıştır. İHA teknolojilerinden sağlanan yüksek çözünürlüklü veriler obje heterojenliklerinin çok daha belirginleşmesinin önünü açmış, segmentasyon ve sınıflandırma işlemlerinde ciddi oranda performans artışı beraberinde getirmiştir. Bu sebeple, son yıllarda sınıflandırma sürecinde performans artırımı hakkındaki çalışmalar yaygınlaşmış, uzay ve hava kaynaklı verilerden türetilen yardımcı veri setlerinin füzyonunu içeren yaklaşımlar ilgi odağı olmuştur. Bu çalışmada, Gebze Teknik Üniversitesi kampüsü sınırları içerisinde çok sayıda arazi örtüsü ve arazi kullanımı (AÖ/AK) sınıfının yer aldığı bir çalışma alanında i) çok-bantlı (multispektral, MS) İHA hava fotoğraflarından yüksek çözünürlüklü ortomozaik elde edilmesi, ii) yardımcı veri setlerinin ve farklı sınıflandırıcıların kullanıldığı durumda AÖ/AK haritaları üretimindeki yaklaşımların etkinliğinin belirlenmesi ve iii) yeryüzü topoğrafyası üzerinde bulunan tekil nesnelerin bağımsız yüksekliklerini 3B olarak tasvir eden normalize dijital yüzey modeli (NDYM)'nin İHA verilerinden üretimi ve yardımcı veri olarak kullanımının objektanlı sınıflandırma doğruluğu üzerindeki etkilerinin araştırılması hedeflenmiştir. Çalışma hedefleri doğrultusunda dört farklı veri seti üretilmiş ve rastgele orman, destek vektör makineleri, aşırı gradyan artırımı makine öğrenme algoritmaları ile sınıflandırılmıştır. Bu veri setlerinin tasarlanmasında spektral bilgi, indis, doku, geometri, NDYM özelliklerinin kombinasyonu ve özyinelemeli özellik seçimi yönteminden faydalanılmıştır. NDYM verisinin yalnızca 5-bantlı (mavi, yeşil, kırmızı, kırmızı kenar, yakın kızılötesi) görüntünün sınıflandırılmasında ek özellik şeklinde kullanımı ve NDYM'nin segmentasyon sürecine bant olarak eklenmesi (6-bantlı) ile hem sınıflandırma hem de segmentasyon aşamaları üzerindeki etkisi ayrı ayrı incelenmiştir. Geniş çaplı doğruluk analizleri neticesinde, NDYM verisinin sınıflandırma ve segmentasyon sürecine dahil edilmesinin, tüm sınıflandırıcılarda performans artışı sağladığı belirlenmiştir. XGBoost algoritmasının ve NDYM'nin dahil olduğu veri setinin kullanımıyla üretilen tematik haritanın %94.65 değeri ile en yüksek genel doğruluk değerini gösterdiği belirlenmiştir. NDYM'nin veri setine dahil edilmesiyle, XGBoost algoritmasının sınıflandırma sonucunda genel doğruluk %4 oranında artarken, sınıf bazlı gerçekleştirilen F1 skor değeri analizlerinde yol ve beton çatı sınıfı özelinde sırasıyla %8 ve %11 oranında dikkate değer bir doğruluk artışı olduğu gözlemlenmiştir. En yüksek doğruluğu gösteren tematik haritanın üretiminde rol alan özellikler, SHAP algoritması ile tekil ve sınıf bazlı olarak değerlendirilmiştir. Tematik harita üretiminde, sınıflar arası ayırımında NDYM kaynağının sağladığı yükseklik bilgisinin en yüksek pozitif yönlü etkiyi oluşturduğu görülürken, normalize edilmiş fark bitki örtüsü indisinin (NDVI) ise en düşük etkiye sahip olduğu tespit edilmiştir.

**Anahtar Kelimeler: AÖ/AK, İHA, Makine Öğrenmesi, NDYM, Obje Tabanlı Görüntü Analizi**

## ABSTRACT

In the world, where digitalization momentum is rapidly increasing with the Industry 4.0 revolution, smart technologies are becoming more important day by day and their use is becoming increasingly widespread. Definitions such as smart cities, smart agriculture, smart forestry have become encountered in every aspect of daily life. In the process of intelligence that emerges on the basis of digitalization, mapping data and technologies are among the most important tools at the heart of applications. Space-borne and airborne mapping technologies provide much faster access to digital data in much larger areas compared to terrestrial technologies, and make it possible to obtain this data repeatedly in desired periods. The data obtained directly digitally are converted into two- and three-dimensional (2D and 3D) final maps with high geolocation and spectral accuracy after the calibration processes are carried out rapidly. In addition to providing 2D and 3D topographic descriptions, these maps can be used for many thematic purposes on the basis of classifying all natural and man-made objects in target areas according to their characteristics. This theme appears in a wide variety of ways, sometimes such as traffic regulation of a metropole, sometimes monitoring plant species, phenological stages and health, sometimes determining forest stand heights, sometimes detecting, monitoring and managing a disaster. Each thematic map to be produced contains different scales and requirements depending on the nature of the project to be realized. Higher spatial resolutions will be preferred as the detail requirement increases for the objects to be included in the thematic map.

Today, the satellites with the highest spatial resolution are camera-equipped optical systems and provide data with a ground sampling distance of approximately 0.3 m. This spatial resolution is limited, especially in the high-precision identification and classification of small and detail-dense earth objects, and this problem is solved by the use of data obtained from aerial technologies. Traditional airborne technologies, which use sensors placed on platforms such as aircraft and helicopters, provide much higher resolution digital data than satellites. However, the financial costs of these technologies are much higher than satellites. At this point, unmanned aerial vehicle (UAV) technology has emerged as a low-cost alternative solution. In studies that do not require wide coverage, UAV technology allows the repetitive production of large-scale, high-accuracy 2D and 3D maps thanks to the very high spatial resolution, high geolocation accuracy and periodic digital data it provides rapidly from low flight altitudes. High-resolution data provided by UAV technology has paved the way for object heterogeneities to become more evident and has brought about a significant increase in performance in segmentation and classification processes. However, rapidly developing technology and especially the need for quality improvement of smart systems necessitate constantly increasing the accuracy criterion in object classifications. Classification problems, which are frequently encountered especially in complex map bases with rich information content, should be overcome by the production and use of auxiliary data. There are many scientific studies on this subject in the world literature. Among these studies, approaches that involve the fusion of auxiliary data sets derived from space-borne and airborne data are the focus of attention.

In this study, in a study area where many different land classes are located within the Gebze Technical University Campus, i) obtaining high resolution orthomosaic from multi-spectral (MS) UAV aerial photos, ii) on this orthomosaic, including spectral, texture and geometry features, determination of the effectiveness of data sets in the

production of land cover and land use (LULC) maps when different classifiers are used, and iii) production of the normalized digital surface model (NDSM), which presents the independent heights of individual objects on the earth's topography in 3D, from UAV data and investigate the effects of using NDSM as the auxiliary data on object-based classification accuracy. Although the number of studies in the world literature on the production of UAV NDSM and its use as auxiliary data in object-based classification is very limited, no study on the subject has been found in our country.

In line with the study objectives, four different data sets were produced and classified with random forest, support vector machines, and extreme gradient boosting machine learning algorithms. The first data set (V1) contains only the spectral and index features, the second data set (V2) contains the texture and geometry features added to these features, the third data set (V3) contains NDSM information in addition to all features, while the fourth data set (V4) contains the recursive feature elimination analysis of the V3 data set. Subject to feature selection, it consists of the features that have the highest effect on model accuracy. By using NDSM data only as an additional feature in the classification of the 5-band (blue, green, red, red edge, near infrared) image and adding NDSM as a band to the segmentation process (6 bands), its effects on both classification and segmentation stages were analyzed separately. As a result of comprehensive accuracy analyses, it was determined that including NDSM data in the classification and segmentation process increased the performance of all classifiers. When evaluated specifically for data sets, the V3 data set, designed by including NDSM data, provided the highest accuracy in all algorithms. The XGBoost algorithm was the highest performing classification algorithm with an overall accuracy value of 94.65%. As a result of classifying the V3 data set with the XGBoost algorithm, while the overall accuracy was increased as 4%, a significant increase as 8% and 11%, respectively was observed in the accuracy of the road and concrete roof classes in class-based F1 Score analyses. In addition, the effects of the features in the V3 data set on the classification result were evaluated individually and on a class basis with the SHAP algorithm. In thematic map production, it was determined that the elevation information provided by the NDSM source has the highest positive effect on class distinction, while the normalized difference vegetation index (NDVI) has the lowest effect.

**Keywords: LULC, UAV, Machine Learning, NDSM, Object Based Image Analysis**

## TEŐEKKÜR

Tez alıřmam boyunca desteęini esirgemeyen, bilgi ve tecrübeleriyle yol gsteren deęerli tez danıřman hocam Prof. Dr. Umut Gneř SEFERCİK'e,  
Tez alıřmam srecinde fikirleriyle ve desteęiyle katkı saęlayan deęerli alıřma arkadařım Arř. Gr. Muhammed Yusuf ZTRK'e  
GT Harita Mhendislięi Blm tm alıřma arkadařlarıma ve hocalarıma,  
Son olarak tm sre boyunca en byk desteęim olan eřim Dr. Nur YAęMUR AYDIN ve bu gnlere gelmemde byk pay sahibi olan aileme,  
Teřekkrlerimi sunarım.



# İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	vi
ABSTRACT	vii
TEŞEKKÜR	ix
İÇİNDEKİLER	x
SİMGELER ve KISALTMALAR DİZİNİ	xii
ŞEKİLLER DİZİNİ	xv
TABLolar DİZİNİ	xvii
1. GİRİŞ	1
1.1. Motivasyon	4
1.2. Çalışmanın Yeri ve Önemi	6
1.3. Çalışmanın Yapısı	7
2. LİTERATÜR ÇALIŞMASI	9
3. ÇALIŞMA ALANI	18
4. METODOLOJİ	20
4.1. Ortomozaik Üretiminde Fotogrametrik İşlem Adımları	21
4.1.1. İHA ile Görüntü Alımı	22
4.1.2. Geometrik ve Radyometrik Düzeltme	25
4.1.3. 3B Fotogrametrik Ürünlerin Üretimi	34
4.2. AÖ/AK Sınıflandırma	37
4.2.1. Pikel Tabanlı Görüntü Sınıflandırma	38
4.2.2. Obje Tabanlı Görüntü Sınıflandırma (OTGS)	39
4.2.3. Özellik Çıkarımı	45
4.2.4. Rastgele Orman	50
4.2.5. Destek Vektör Makineleri	51
4.2.6. Aşırı Gradyan Artırma (XGBoost)	55
4.2.7. GridsearchCV	58
4.2.8. Özellik Seçimi	59
4.2.9. Doğruluk Analizi	60
5. UYGULAMA VE BULGULAR	63
5.1. Görüntü Alımı	63
5.2. Ortomozaik Üretimi	68
5.3. Normalize Dijital Yüzey Modeli (NDYM) Üretimi	78
5.4. Görüntü Segmentasyonu	84
5.5. Eğitim Verilerinin Oluşturulması	88
5.6. AÖ/AK Sınıflandırma	90
5.6.1. Rastgele Orman	93
5.6.2. Destek Vektör Makineleri	99
5.6.3. Aşırı Gradyan Artırma	104
5.6.4. Tematik Doğruluk Değerlendirmesi ve Bulgular	108
6. SONUÇLAR	114
KAYNAKLAR	116

ÖZGEÇMİŞ	136
TEZ METNİNDEN TÜRETİLEN YAYINLAR/SUNUMLAR	137
EKLER	138



## SİMGELER ve KISALTMALAR DİZİNİ

f	: Odak Uzaklığı
g	: Sensör Kazancı
$L_{(CRP(\lambda))}$	: Panel Radyans Değeri
$L(\lambda)$	: Piksel Radyans Değeri
$p(\lambda)$	: Yüzey Reflektans Değeri
$p_{CRP}$	: Panel Reflektans Değeri
$R^2$	: Korelasyon Katsayısı
$t_e$	: Pozlama Süresi
$V(x,y)$	: Vinyet Düzeltmesi
W	: Ağırlık Katsayısı
$\mu$	: Piksel boyutu
$\sigma$	: Standart Sapma
$\Omega(f)$	: Regülerizasyon
AK	: Arazi Kullanımı
AÖ	: Arazi Örtüsü
ARI1	: Anthocyanin Reflectance Index 1
ARI2	: Anthocyanin Reflectance Index 2
BDN	: Bağımsız Denetim Noktası
BLUH	: Bundle Block Adjustment Leibniz University Hannover
BRI	: Blue Red Index
CART	: Classification and Regression Tree
CIVE	: Color Index of Vegetation
CIWI	: Combined Index for Water Identification,
DAM	: Dijital Arazi Modeli
DM	: Data Metrics
DN	: Digital Number
DVI	: Difference Vegetation Index
DYM	: Dijital Yüzey Modeli
ER	: Excessive Red
ERTS	: Earth Resources Technology Satellite
ESP	: Estimation of Scale Parameter
EVI	: Enhanced Vegetation Index
ExG	: Excess Green Index
FN	: False Negative
FP	: False Positive
GLI	: Green Leaf Index
GLCM	: Grey Level Cooccurrence Matrix
GNSS	: Global Navigation Satellite Systems
GOSAVI	: Green Optimized Soil Adjusted Vegetation Index
GPS	: Global Positioning System
GRI	: Green Ratio Index
GRVI	: Green-Red Vegetation Index
H	: Uçuş Yüksekliği
IMU	: Inertial Measurement Unit
IPVI	: Infrared Percentage Vegetation Index
İHA	: İnsansız Hava Aracı
K	: Kırmızı

KK	: Kırmızı Kenar
KNN	: K-En Yakın Komşuluk
KOH	: Karesel Ortalama Hata
LAI	: Leaf Area Index
LiDAR	: Light Detection and Ranging
LV	: Lokal Varyans
M	: Mavi
MAE	: Ortalama Mutlak Hata
MCARI	: Modified Chlorophyll Absorption Ratio Index
MÖ	: Makine Öğrenmesi
MRENDVI	: Modified Red Edge Normalized Difference Vegetation Index
MRESR	: Modified Red Edge Simple Ratio
MS	: Multispektral
MSE	: Ortalama Hata Karesi
MSAVI2	: Modified Soil-Adjusted Vegetation Index
MSR	: Modified Simple Ratio
MVI	: Modified Vegetation Index
NASA	: National Aeronautics and Space Administration
NB	: Naive Bayes
NDVI	: Normalized Difference Vegetation Index
NDYM	: Normalize Dijital Yüzey Modeli
NDRE	: Normalized Difference Red Edge
NDRGI	: Normalized Difference Red Green Index
NDWI	: Normalized Difference Water Index
NLI	: Non-Linear Vegetation Index
OA	: Overall Accuracy
OAA	: One Against All
OA0	: One Against One
OTGA	: Obje Tabanlı Görüntü Analizleri
P	: Kesinlik (Precision)
PA	: Producer Accuracy
PSRI	: Plant Senescence Reflectance Index
R	: Duyarlılık (Recall)
RF	: Random Forest
RGB	: Red Green Blue
RGBVI	: Red Green Blue Vegetation Index
RGR	: Red/Green Reflectance Ratio
RI	: Redness Index
RoC	: Lokal Varyansın Değişim Oranı
RTK	: Real-time Kinematic
RTF	: Radyal Tabanlı Fonksiyon
RVI	: Ratio Vegetation Index
RRI	: Red Ratio Index
SAR	: Synthetic Aperture Radar
SAVI	: Soil Adjusted Vegetation Index
SFM	: Structure From Motion
SHAP	: SHapley Additive exPlanations
SIFT	: Scale Invariant Feature Transform
SIPI	: Structure Insensitive Pigment Index
SR	: Simple Ratio

SVM	:	Support Vector Machine
TGI	:	Triangular Greenness Index
TP	:	True Positive
TVI	:	Triangular Vegetation Index
UA	:	User Accuracy
UTM	:	Universal Transverse Mercator
VEG	:	Vegetativen
VI <sub>opt</sub>	:	Optimal Vegetation Index
WGS84	:	World Geodetic System 1984
XGBoost	:	Extreme Gradient Boosting
Y	:	Yeşil
YKN	:	Yer Kontrol Noktası
YKÖ	:	Yakın Kızılötesi
YÖA	:	Yer Örnekleme Aralığı
YSA	:	Yapay Sinir Ağları



## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
<b>Şekil 1.1:</b> Çalışma yapısına ait genel başlıklar.	8
<b>Şekil 3.1:</b> Gebze Teknik Üniversitesi kampüs alanı ve AÖ/AK sınıfları (a-k).	18
<b>Şekil 4.1:</b> Tez kapsamında uygulanan metodoloji.	21
<b>Şekil 4.2:</b> Ortomozaik üretiminde fotogrametrik iş akışı.	21
<b>Şekil 4.3:</b> Bindirmeli alan içerisindeki noktaların farklı kamera bakış açıları ile görüntülenmesi.	24
<b>Şekil 4.4:</b> YKN örnekleri: (a) yağlı boya ile tesis, (b) damalı tesis, (c) kireçli taş ile tesis, (d) mobil polikarbon tesis.	26
<b>Şekil 4.5:</b> Metaveri içerisinde yer alan GPS koordinatları.	27
<b>Şekil 4.6:</b> Radyometrik kalibrasyon uygulama adımları.	31
<b>Şekil 4.7:</b> Kompozit (RGB) ve beş mono banta ait görüntülerin metaveri dosyası.	31
<b>Şekil 4.8:</b> Kalibrasyon paneli örnekleri: (a) Micasense RP06, (b) MAPIR V2, (c) üç farklı renk aralığındaki manuel üretilen paneller.	33
<b>Şekil 4.9:</b> MAPIR V2 panele ait reflektans değerleri.	34
<b>Şekil 4.10:</b> DYM ve DAM kavramlarının temsili gösterimi.	35
<b>Şekil 4.11:</b> İHA verilerinden üretilen örnek ürünler: (a) seyrek nokta bulutu, (b) yoğun nokta bulutu, (c) DYM, (d) ortomozaik.	36
<b>Şekil 4.12:</b> Obje tabanlı görüntü analizi iş akışı.	40
<b>Şekil 4.13:</b> Farklı ölçek parametresi değerlerinde segmentasyon sonuçları.	44
<b>Şekil 4.14:</b> GLCM yönleri.	48
<b>Şekil 4.15:</b> RF algoritması ağaç yapısı ve çalışma şeması.	51
<b>Şekil 4.16:</b> İki sınıflı veri seti için SVM ile hiper düzlemlerin belirlenmesi.	52
<b>Şekil 4.17:</b> OAO ve OAA yöntemiyle belirlenen hiper düzlemler.	53
<b>Şekil 4.18:</b> Çok sınıflı veri seti için SVM ile hiper düzlemlerin belirlenmesi.	54
<b>Şekil 4.19:</b> XGBoost çalışma şeması.	56
<b>Şekil 4.20:</b> Örnek hata matrisi.	61
<b>Şekil 5.1:</b> Görüntü alımı kamera açısı.	64
<b>Şekil 5.2:</b> İHA Uçuş planı.	65
<b>Şekil 5.3:</b> Polikarbon yer kontrol noktası örneği.	66
<b>Şekil 5.4:</b> İHA iniş – kalkış alanı.	67
<b>Şekil 5.5:</b> Görüntü alım anındaki kamera konumları ve bindirmeli alanlardaki fotoğraf sayısı.	68
<b>Şekil 5.6:</b> Yöneltilme işlemleri tamamlanmış hava fotoğrafları.	68
<b>Şekil 5.7:</b> Çalışma alanını kapsayan seyrek nokta bulutu.	69
<b>Şekil 5.8:</b> YKN'lerin çalışma alanı üzerindeki dağılımı.	70
<b>Şekil 5.9:</b> YKN dağılımı ve hata elipsleri.	71
<b>Şekil 5.10:</b> Görüntü çekimi örneği ve altı farklı bantta MAPIR panel görüntüsü.	73
<b>Şekil 5.11:</b> MAPIR panel maskeleyme işlemi: (a) öncesi, (b) sonrası.	74
<b>Şekil 5.12:</b> Agisoft ortamında MAPIR reflektans değerlerinin tanımlanması.	74
<b>Şekil 5.13:</b> Filtreleme işlemi uygulanmamış (a) ve uygulanmış (b) nokta bulutu.	76

<b>Şekil 5.14:</b> Ortofoto ve iki farklı kaynaktan üretilen nokta bulutu: (a) RGB kaynak, (b) 5-bantlı kaynak.	76
<b>Şekil 5.15:</b> DYM sonucu.	77
<b>Şekil 5.16:</b> Radyometrik kalibrasyon adımı uygulanmamış 5-bantlı ortomozaik.	78
<b>Şekil 5.17:</b> Radyometrik kalibrasyon adımı uygulanmış 5-bantlı ortomozaik.	78
<b>Şekil 5.18:</b> NDYM üretimi iş akış diyagramı.	80
<b>Şekil 5.19:</b> Üretilen DYM (üst) ve DAM (alt).	82
<b>Şekil 5.20:</b> Üretilen 0.1 m grid aralıklı NDYM.	83
<b>Şekil 5.21:</b> 5 bant ortomozaik için ölçek parametresinin belirlenmesinde ESP-2 grafiği.	84
<b>Şekil 5.22:</b> NDYM bantının segmentasyon işlemi üzerindeki etkisi.	86
<b>Şekil 5.23:</b> 5-bant (a) ve 6-bant (b) veri setleri için segmentasyon sonucu.	87
<b>Şekil 5.24:</b> 5-bant (a) ve 6-bant (b) segmentasyon sonuçları için tüm sınıflara ait örnek veriler.	89
<b>Şekil 5.25:</b> Doğruluk değerlendirmesi amacıyla üretilen referans veriler.	92
<b>Şekil 5.26:</b> 5-bantlı ortomozaik veri ve RF algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c), V4 (d) veri setleri için üretilen tematik haritalar.	95
<b>Şekil 5.27:</b> 6 bantlı ortomozaik veri ve RF algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.	96
<b>Şekil 5.28:</b> RF algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.	97
<b>Şekil 5.29:</b> 5-bant RF F1 skor değeri.	98
<b>Şekil 5.30:</b> 6-bant RF F1 skor değeri.	99
<b>Şekil 5.31:</b> 5 bantlı ortomozaik veri ve SVM algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c), V4 (d) veri setleri için üretilen tematik haritalar.	100
<b>Şekil 5.32:</b> 6 bantlı ortomozaik veri ve SVM algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.	101
<b>Şekil 5.33:</b> 5-bant SVM F1 skor değeri.	102
<b>Şekil 5.34:</b> 6-bant SVM F1 skor değeri.	102
<b>Şekil 5.35:</b> SVM algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.	103
<b>Şekil 5.36:</b> 5-bantlı ortomozaik veri ve XGBoost algoritmasının kullanımıyla V1 (a) ve V2 (b) veri setleri için üretilen tematik haritalar.	105
<b>Şekil 5.37:</b> 6-bantlı ortomozaik veri ve XGBoost algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.	106
<b>Şekil 5.38:</b> XGBoost algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.	107
<b>Şekil 5.39:</b> 5-bant XGBoost F1 skor değeri.	108
<b>Şekil 5.40:</b> 6-bant XGBoost F1 skor değeri.	108
<b>Şekil 5.41:</b> AÖ/AK tematik haritalarının veri setine göre doğruluk analizleri.	110
<b>Şekil 5.42:</b> Sınıf bazlı SHAP analizi sonucu: (a) En etkili özellikler, (b) en düşük etkiye sahip özellikler.	111

## TABLolar DİZİNİ

	<u>Sayfa</u>
<b>Tablo 4.1:</b> Bant deęerlerinden türetilen spektral bilgiler.	45
<b>Tablo 4.2:</b> Bant oranlarından türetilen indisler.	46
<b>Tablo 4.3:</b> Geometrik özellikler.	47
<b>Tablo 4.4:</b> GLCM doku özellikleri	49
<b>Tablo 5.1:</b> DJI Phantom 4 Multispektral İHA teknik özellikler.	64
<b>Tablo 5.2:</b> CHC i80 GNSS alıcısı teknik özellikler.	66
<b>Tablo 5.3:</b> YKN'lere ait koordinatlar ve hesaplanan konum doęruluęu.	70
<b>Tablo 5.4:</b> YKN ve BDN'lere ait koordinatlar ve hesaplanan konum doęruluęu.	72
<b>Tablo 5.5:</b> Yer noktalarının elde edilmesinde kullanılan otomatik filtreleme parametreleri.	81
<b>Tablo 5.6:</b> İki farklı veri seti için belirlenen segmentasyon parametreleri ve üretilen görüntü objesi sayısı.	86
<b>Tablo 5.7:</b> Çalışma kapsamında kullanılan veri setleri.	88
<b>Tablo 5.8:</b> Eğitim verilerinin sınıf bazlı dağılımları.	90
<b>Tablo 5.9:</b> Veri setleri ve sınıflandırıcılara göre üretilen tematik haritalar.	90
<b>Tablo 5.10:</b> GridSearchCV yöntemi ile belirlenen parametre deęerleri.	92
<b>Tablo 5.11:</b> RF için özyinelemeli özellik seçimi yöntemi ile belirlenen etkisiz özellikler.	93
<b>Tablo 5.12:</b> XGBoost için özyinelemeli özellik seçimi yöntemi ile belirlenen özellikler.	104
<b>Tablo 5.13:</b> Tematik doęruluk deęerlendirmesi.	109

# 1. GİRİŞ

Hızla gelişen kentleşme ve beraberinde artan nüfus oranları neticesinde, doğal kaynakların izlenmesi ve yönetimi, kalkınma planları ve kentsel gelişim stratejileri gibi çalışmalar için güvenilir, temini hızlı ve kolay yorumlanabilir veri ihtiyacı ortaya çıkmıştır [**Thanh Noi and Kappas, 2017**]. Bu noktada arazi örtüsü/arazi kullanımı (AÖ/AK) haritalarının üretimi, ihtiyaç duyulan veriye ulaşmak için oldukça efektif bir yöntem sunmuştur. AÖ, araziyi kaplayan bitki örtüsü ve yapay unsurların tamamını içerirken AK, arazi ile doğrudan ilişkili insan faaliyetleridir [**Burley, 1961**], [**Clawson and Stewart, 1965**]. Herhangi birinde meydana gelen değişimin diğerini de etkilediği bu iki kavram, birbirleriyle son derece ilişkilidir [**Giri, 2012**]. AÖ/AK'daki değişim barınma, gıda ve hammadde üretimi gibi temel insani ihtiyaçların giderilmesi amacıyla ya da afetlerin (deprem, sel, heyelan vb.) ortaya çıkışıyla süreç içerisinde doğal yapıda meydana gelen farklılaşmadır [**DeFries et al., 2004**]. Ekonomik kalkınma ve bölgenin ekolojik yapısına bağlı olarak bu süreç belirli bir hıza sahiptir ve periyodik olarak gözlemlenmesi gerekmektedir [**Guidici and Clark, 2017**].

Hava ve uzay kaynaklı uzaktan algılama teknolojilerinin, geniş çaplı kapsama alanları ve tekrarlı veri temini gibi avantajları, saha çalışmalarının önüne geçmekte ve AÖ/AK haritalandırma yaklaşımlarında son derece faydalı bir araç olmaktadır [**Foody, 2002**], [**Townshend et al., 1991**], [**Hansen et al., 2013**]. Uydular, Dünya yüzeyinden binlerce kilometre uzaklıkta sabit yörüngelerde hareket etmekte ve mevcut donanımlarına bağlı olarak çeşitli zamansal ve mekansal çözünürlük değerlerine sahiptirler. Sensörlerin teknik yapısına bağlı mekansal çözünürlük kavramı, metre düzeyinden cm hassasiyetine kadar değişiklik göstermektedir. Temelinde algılamadaki enerji kaynağına bağlı olarak aktif ve pasif algılama prensibiyle çalışan sistemler, optik ve radar sensörlerini içermektedir. Uzaktan algılama sensörleri, yansıyan (optik sensörler), yayılan (termal kızılötesi veya pasif mikrodalga sensörleri) veya saçılan (aktif radar sensörleri) enerjiyi çeşitli fiziksel temellerle kaydetmekte ve nesne yüzeyinin elektromanyetik özelliklerine dayalı olarak bilgi çıkarımı sağlamaktadır [**Joshi et al., 2016**].

Optik sensörler, nesnelere yansıyan elektromanyetik enerjiyi kaydetmekte ve buna bağlı olarak atmosferik değişkenlerden (bulutluluk oranı vb.) etkilenmektedirler [Piragnolo, 2018]. Optik sensörlerle kaydedilen ürünler, spektral yansıma değerlerine dayalı olarak arazi özellikleri hakkında farklı bilgiler sunabilen ve çeşitli indekslerin üretimiyle AÖ/AK bilgilerini vurgulayabilen, belirli spektral aralıklı bantları içeren çok bantlı (multispektral, MS) görüntülerden oluşmaktadır. Bunun aksine, radar sinyalleri her sensör için yalnızca tek bir dalga boyu üretmekte ve arazi örtüsü ile etkileşime girerek yapısal özellikler hakkında veri toplamaktadır. Yüzey pürüzlülüğü, nem oranı, iletkenlik gibi unsurlar aktif radardan geri saçılan enerjide farklılık oluşturmakta ve sınıflar arası ayırmada fayda sağlamaktadır. Nesne yüzeylerinden alınan saçılım, polarizasyon kombinasyonlarıyla çeşitlendirilebilmekte ve daha zengin bilgi içeriği sağlanabilmektedir.

Geniş ölçekli çalışmalar için yeryüzü hakkında oldukça etkili bir bilgi kaynağı oluşturan uydular, küçük ölçekli çalışmalar için yeterli çözünürlüğü kullanıcılara sunmamaktadır. Büyük veri boyutu, görüntülerin işleme süresi, farklı sensör kaynaklarından alınan verilerin entegre kullanımı gibi konular hala bu teknolojilerin uygulanabilirliğini zorlaştırmaktadır [Zhao et al., 2022]. Uydulara alternatif olarak uçaklarla daha alçak irtifada gerçekleştirilen görüntü alımı yüksek çözünürlük sağlarken, beraberinde yüksek maliyet ve tecrübeli operatör ihtiyacı ile çok fazla tercih edilememektedir.

Son yıllarda ise sahip olduğu yüksek mekansal ve zamansal çözünürlük, ekonomik çözümler sunması ve kolay ulaşılabilirliği ile İnsansız Hava Aracı (İHA), uzaktan algılamanın birçok alanında sıkça başvurulan bir kaynak haline gelmiştir [Al-Najjar et al., 2019], [Kalantar et al., 2017]. Coğrafi bilgi sistemi, veri tabanları, tarımsal uygulamalar, kentsel planlama, arazi örtüsü tespiti, doğal afet gözlemi gibi birçok alanda İHA'dan destek alınmaktadır [De Oliveira Silva et al., 2019], [Delavarpour et al., 2021], [Akar, 2017]. Görünür bölgede algılama ve veri kaydı yapabilen üç bantlı İHA'ların (Kırmızı-Yeşil-Mavi, RGB) yanı sıra daha geniş spektral aralıkta bilgi kaydedebilen çok bantlı sensörler entegre edilmiş İHA'lar da günümüzde bilimsel amaçlı çalışmalarda sıkça başvurulan bir araç olmuştur [Christiansen et al., 2017], [Barrero and Perdomo, 2018]. Görünür bölgede algılama yapan sensörler AÖ tespiti için uygun bir yaklaşım sağlayabilirken, MS sensörlere sahip İHA'ların yardımı ile

AK hakkında da birçok çıkarım yapılabilmekte ve haritalandırılabilir [Giri, 2012].

Çok bantlı görüntülerin sınıflandırılması yıllardır uzaktan algılama alanında çalışılan ve çevresel planlamalara, bitki sağlığı gözlemi gibi tarımsal uygulamalara altlık oluşturmasıyla ilgi gören popüler bir konudur [Kulkarni and Lowe, 2016], [Zhang et al., 2022], [Doughty and Cavanaugh, 2019]. Bu sebeple, sınıflandırma doğruluğunu arttırmak üzerine birçok yaklaşım ve sınıflandırıcı geliştirme çabası gösterilmiştir [Zafari et al., 2019]. Uydularla kıyaslandığında İHA'lar bahsedilen avantajlarının yanı sıra yüksek bindirme oranıyla alınan görüntülerin sağladığı stereo görüş sayesinde, çok daha hassas dijital yüzey modeli (DYM) üretebilme potansiyelleri, sınıflandırma çalışmalarında tercih edilmelerine ve performans arttırımı amacıyla farklı yaklaşımların denenebilmesine olanak sağlamıştır [Beumier and Idrissa, 2016], [Gil-Docampo et al., 2020], [Dubbini et al., 2016], [Yang et al., 2021].

Uzaktan algılanan verilerden tematik haritalama, tipik olarak bir görüntü sınıflandırmasına dayanmakta ve görsel ya da bilgisayar destekli analiz ile gerçekleştirilebilmektedir. Uzaktan algılanmış görüntülerin sınıflandırmasında birçok yöntem kullanılmaktadır ve doğru yöntemin seçimi son derece önemlidir [Bhatt, 2022]. Makine öğrenmesi (MÖ) algoritmaları son 20 yıllık süreçte popüleritesini arttırmış ve sıkça tercih edilir bir sınıflandırma tekniği haline gelmiştir [Mountrakis et al., 2011], [Pal, 2005], [Pal and Mather, 2003]. Literatürde yer alan sınıflandırma çalışmaları incelendiğinde, kontrollü sınıflandırma yöntemlerinin kontrolsüz sınıflandırma yöntemlerine göre üstün performans gösterdiği görülmüştür [Song et al., 2005]. Kontrolsüz sınıflandırmanın verimli çalışabilmesi için gereken spesifik bilgiler ve piksellerin spektral karşılılıklarının sınıflar arası ayırıda yetersiz kalması, bu sınıflandırıcıların kontrollü sınıflandırma yöntemlerinin arkasında kalmalarına sebep olmaktadır [Zafari et al., 2019].

Çok bantlı görüntülerin tekil kullanımı yüksek doğruluklu bir sınıflandırma için yeterli veriyi içermemektedir [Bhatt, 2022]. İhtiyaç duyulan ek veriler, yardımcı veri olarak adlandırılmakta ve bu verilerin oluşturulması, ardından sınıflandırma sürecine dahil edilmesi sonuçları iyileştirmektedir. Yardımcı veriler spektral bilgiye bağlı kısıtlamaları ortadan kaldırmalarıyla sınıflandırma sürecinde önemli bir role sahiptir. Spektral bilgilerden türetilen indisler (normalize edilmiş fark bitki indeksi (normalized

difference vegetation index, NDVI), SAVI (soil adjusted vegetation index) vb.), geometrik özellikler, doku özellikleri ve yükseklik bilgisi sıklıkla faydalanılan yardımcı verilerdir [Mahlein et al., 2013], [Huang et al., 2015], [Liu et al., 2020]. Sınıflandırma sürecine dahil edilen her bir değişken sonuçlar üzerinde bağımsız etkiye sahip olabilmektedir. Bu noktada çok değişkenli bir sınıflandırmada parametreler arasında sonuç üzerinde en etkin olanı belirleme ve veri kompleksliğini azaltma ihtiyacı oluşmaktadır [Hughes, 1968].

## 1.1. Motivasyon

Nüfusun çoğunluğunun kentsel alanlarda bulunması ya da gün geçtikçe bu bölgelerde yoğunlaşması, mevcut kaynakların kullanımının planlanması gereksinimini doğurmaktadır [Gaur et al., 2021]. Kaynakların yönetimi amacıyla kalkınma planlarının tasarlanması, AÖ/AK haritalarının uygulanmasıyla çok daha pratik ve ekonomik bir hal almaktadır. Bu haritalara olan ihtiyaç beraberinde tematik harita üretiminde en doğru yöntem ve kaynağın araştırılması gereksinimini doğurmakta, bu hedefle yola çıkıldığında birçok kaynak ve yöntemle karşılaşmaktadır.

Düşük irtifalı uçuş imkanı, kullanıcı dostu pratik çözümler sunması, yüksek mekansal ve zamansal çözünürlük, ekonomik işgücü gereksinimi ve hava koşulları göz önünde bulundurularak uçuş planlaması ile görüntü alımı gibi avantajlar, İHA'ları bu amaç için ideal bir cihaz konumuna getirmektedir. Yalnızca görünür dalga boyunda algılama yapabilen görüntüleme sistemleri sağladıkları kısıtlı spektral bilgi nedeniyle çok sınıflı heterojen çalışma alanlarındaki uygulamalarda (bina çıkarımı vb.), benzer özelliklere sahip su geçirimsiz alanların ayırımında zorlanmakta ve yetersiz kalmaktadır. Küçük ölçekli çalışmalar için yüksek çözünürlükleri ile İHA'ların ihtiyaç duyulan performansı karşılamaları, çok bantlı algılama gibi güncel bir teknolojiyi kullanıcılar ile buluşturarak kısıtlı spektral bilgiye bağımlılığı ortadan kaldırmış, MS İHA'ların bu alanda uygulanabilirliğini araştırma düşüncesini şekillendirmiş ve tez çalışmasının çıkış noktasını oluşturmuştur.

Bu çalışmada, bahsedilen avantajlar ve gerçekleştirilmesi hedeflenen analizler doğrultusunda Gebze Teknik Üniversitesi kampüs sınırları içerisinde yer alan; kırmızı çatı, beton çatı, karayolu, bisiklet yolu, su, geniş-iğne yapraklı ağaç, seyrek-yoğun bitki örtüsü, gölge ve toprak olmak üzere, çok sınıflı heterojen yapıya sahip olan bir bölge çalışma alanı olarak belirlenmiş ve çok bantlı yüksek çözünürlüklü DJI Phantom

4 RTK İHA'dan sağlanan veriler neticesinde ortomozaik elde edilmiştir. Ortomozaik verisi altlık olarak kullanılmış ve çok sınıflı bir sınıflandırma işleminde, çeşitli veri setleri ve MÖ algoritmaları yardımıyla performans arttırımı odaklı yeni bir yaklaşım sunulmuştur. Güncel MÖ algoritmaları, arazi üzerinde yer alan doğal ya da yapay unsurların sınıflandırılmasında sıklıkla tercih edilen yöntemlerdir ve çok bantlı uydu görüntüleri ile gerçekleştirilen birçok çalışmada maksimum olabilirlik (maximum likelihood), en kısa mesafe (minumum distance) ve K-en yakın komşuluk (KNN) gibi klasik sınıflandırıcılara göre üstün performans göstermiştir [Mountrakis et al., 2011], [Zhou et al., 2021]. Çok bantlı İHA ile gerçekleştirilen çalışmalar incelendiğinde ise tarımsal uygulama alanında yoğunlaştığı ve az sayıda sınıfın yer aldığı görülmektedir [Modica et al., 2021], [Romero et al., 2018], [Su et al., 2022], [Narmilan et al., 2022].

Çalışmada 11 farklı sınıf içeren 10 cm çözünürlüklü 5-bantlı (mavi, yeşil, kırmızı, kırmızı kenar, yakın kızılötesi) ortomozaik verisinin altlık olarak değerlendirildiği ve AÖ/AK tespitinde sıkça tercih edilen Rastgele Orman (Random Forest, RF), Destek Vektör Makineleri (Support Vector Machine-SVM) ve XGBoost algoritmalarının kullanıldığı obje tabanlı sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sürecinde, spektral bilgilerden üretilen doku, indis ve geometrik özelliklere ek olarak, yüksek doğrulukta üretilen normalize dijital yüzey modelinin (NDYM) yardımcı veri olarak değerlendirildiği yeni bir yaklaşım uygulanmıştır. DYM, yeryüzü ve üzerindeki yapay (bina, yol, kaldırım vb.) ya da doğal unsurların (bitki örtüsü vb.) tamamını içeren nesnelerin ve buldukları topografyanın 3B kartografik tasviridir. DYM, İHA kaynaklı görüntülerin fotogrametrik değerlendirilme sürecinde üretilen yeryüzüne ait ilk 3B modeldir. Dijital Arazi Modeli (DAM) ise DYM'nin zemin üstü nesnelerinin filtrelenmesiyle, çıplak topografyanın temsil edildiği 3B bir modeldir [Jacobsen, 2014]. NDYM ise bu iki modelin diferansiyelinin alınması yoluyla hesaplanmakta, tekil nesnelerin yüksekliğini ve konum bilgisini içermektedir [Niederöst, 2000], [Straub et al., 2001].

Çok sayıda veriden oluşan girdinin, sonuç ürünlerinde doğruluk arttırımı amacıyla özylenelemeli özellik seçimi (recursive feature selection) yöntemi kullanılmıştır. Belirlenen özellikler ve veri setleri ile sınıflandırma algoritmaları çalıştırılmış ve her bir özelliğin sonuçlara olan etkisinin sınıf bazlı gözlemlenmesi amacıyla SHAP yöntemi kullanılmıştır. Bu şekilde sınıflandırma için kurulan modellerin

yorumlanabilirliđi kolaylařmıř ve her bir deđiřkenin tekil etkisi daha anlařılabilir hale getirilmiřtir. Son olarak farklı sınıflandırıcıların farklı veri setleri üzerindeki performansı istatistiki ve görsel olarak deđerlendirilmiřtir.

## 1.2. alıřmanın Yeri ve Önemi

Literatürde İHA'lar ile gerekleřtirilen birok AÖ/AK alıřması yer almasına rađmen güncel teknolojilere sahip multispektral kamera donanımlı cihazların, ok sınıflı bir alıřma özelinde sınıflandırma performansının MÖ destekli detaylı bir analizinin gerekleřtirildiđi sınırlı sayıda alıřma bulunmaktadır. alıřma kapsamında bu bořluđu gidermek üzere ok bantlı İHA ve bu araçtan elde edilen ortomozaik üzerinden 11 sınıflı bir AÖ/AK analizi gerekleřtirilmiřtir. Tez alıřmasının temel amaları řu řekildedir:

- Tek bantlı (RGB) görüntülerin sebep olduđu kısıtlı spektral bilgi probleminin, ok bantlı görüntü kullanımı ile elimine edilmesi,
- İHA'nın sađladıđı yüksek özünürlük avantajı ile yüksek konumsal dođrulukta yüzey modellerinin üretimi,
- 5-bantlı algılama sistemine sahip İHA'nın radyometrik ve geometrik kalibrasyon iřleminin detaylı analizi,
- Sınıflandırma algoritmaları için optimum parametrelerin belirlenmesi,
- Güncel sınıflandırıcıların performanslarının karřılařtırmalı analizi,
- Sınıflandırma algoritmaları için spektral bilginin benzer ya da yetersiz kaldıđı durumlarda yükseklik bilgisinin efektif kullanımıyla beton ya da beyaz atılı binaların tespiti,
- ok sayıda bileřenin bütünleřik kullanımında, her bir etkenin ađırlıđının MÖ algoritmaları ile deđerlendirilmesi,
- Spektral, doku, geometri ve yükseklik bilgilerinden oluřan farklı veri setlerinin ayrı ayrı analizi ve sınıflandırma dođruluđuunda veri setinin öneminin tespiti,
- NDYM'nin sınıflandırmaya olan dođrudan etkisine ek olarak sınıflandırılan segmentlerin üretimindeki etkisi de ayrıca incelenmiřtir.

Tez alıřmasının yeniliki yanları ise řu řekildedir:

- Teknolojik anlamda gelişme sürecindeki ülkemizde, AÖ/AK tematik haritalarının üretiminde MS İHA teknolojisinin kullanımıyla ulusal literatüre katkı sađlanması,

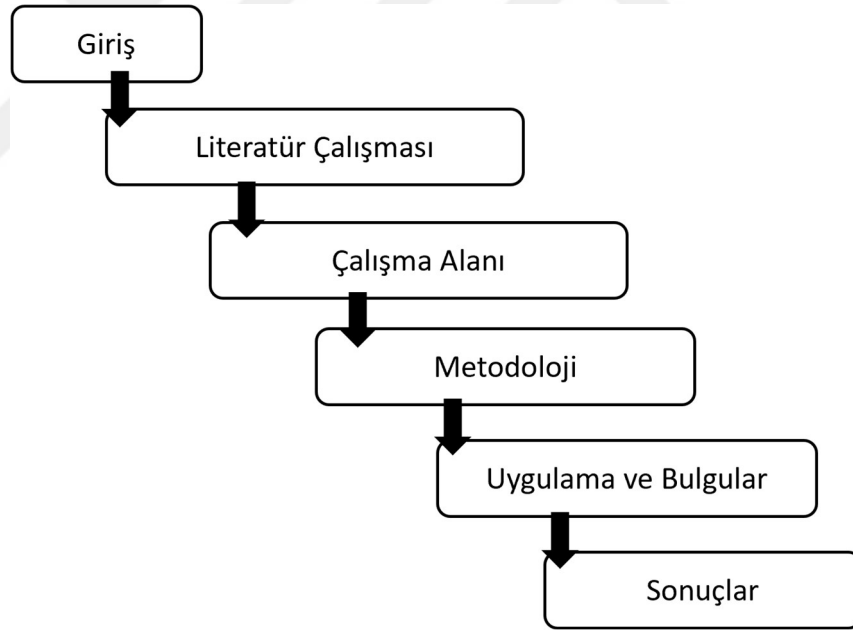
- MS İHA'nın hem kentsel hem kırsal doku içeren çok sınıflı alanlardaki AÖ/AK çalışmalarında kullanılabilirliğinin analizi,
- MS ve tek bantlı görüntülerin fotogrametrik iş akış sürecindeki farklılıklar ve sonuç ürünlerden biri olan nokta bulutunun bölgesel analizi,
- NDYM'nin segmentasyon işlemi üzerindeki etkisinin belirlenmesi,
- Hareketten yapı (structure from motion, SFM) tabanlı ticari, İHA verisi işleme yazılımlarının (Agisoft Metashape, Pix4D, ContextCapture, VisualSFM vb.) sınırlı kalitede sunabildiği DYM'ler yerine gelişmiş işlem süreciyle yüksek kalitede DYM ve DAM üretilmesi ve bu ürünlere bağlı olarak hassas NDYM elde edilmesi,
- Geleneksel çalışmaların yanı sıra yüksek doğrulukta üretilen NDYM'nin MS ortomozaik ile eş çözünürlükte entegre kullanımı sonucunda AÖ/AK sınıflandırma performansında gerçekleşen katma değerın detaylı görsel ve istatistiksel analizi,

Hedeflenen tüm üretimlerin tamamlanmasının ardından, geniş çaplı görsel ve istatistiki analizlerle doğruluk kontrolleri tamamlanmıştır.

### 1.3. Çalışmanın Yapısı

Tez çalışması; giriş, literatür araştırması, materyal ve metodoloji, uygulama ve bulgular, sonuçlar olmak üzere beş ana başlıktan oluşmaktadır **Şekil 1.1**. Giriş bölümü, uzaktan algılama teknolojilerinin yeryüzünün gözlemindeki kullanım alanları, çalışmanın hangi ihtiyaçların karşılanmasında altlık oluşturacağı, çalışma konusunun ortaya çıkışındaki motivasyon kaynakları, İHA gibi güncel teknolojilerin yaygın kullanımı ve bu çalışmadaki ağırlığı hakkında bilgiler vermektedir. Bu bilgilere ek olarak çalışma boyunca ortaya koyulan hedefler ve gerçekleştirilen analizlerin genel özeti, literatürdeki yeri ve sağlayacağı katkılarla ilişkili beklentilere de bu bölümde yer verilmiştir. Literatür çalışması başlığı altında ise, güncel teknolojilerin zamansal değişimi ve etkisi altında bıraktığı uzaktan algılama ve fotogrametrinin tarihçesi, genel hatlarıyla ifade edilmiştir. İHA'nın ortaya çıkışıyla uzaktan algılamanın faydalandığı alanlardaki çeşitliliğin artışı, veri toplamadaki üstün yanları ve dezavantajları gibi konular sunulmuştur. Literatürde yer alan benzer çalışmalar kapsamlı bir şekilde incelenmiş ve detaylı bir şekilde irdelenmiştir. Bu çalışmalarda kullanılan veri kaynakları, yöntemler, sonuçlar, karşılaşılan problemler çok yönlü tartışılmış ve açık

bir şekilde ifade edilmiştir. Çalışma alanı başlığında, tez çalışması kapsamında kullanılan çalışma sahasının konumu ve içerisinde yer alan AÖ/AK sınıfları hakkında detaylı bilgiler verilmiştir. Metodoloji bölümünde, veri setleri, yöntemler ve tercih edilme nedenleri açıklanmıştır. Uygulama ve bulgular başlığı altında, kullanılan yöntemlerde yer alan değişkenler ve bunların sonuçlar üzerindeki etkileri incelenmiştir. Sınıflandırma performansının arttırımında yöntemlerin ve veri setlerinin etkisi irdelenmiş, her bir sınıfın tespitindeki doğruluğun arttırımı için kullanıcının ihtiyaç duyacağı yardımcı veriler ayrı ayrı değerlendirilmiştir. Tercih edilen yöntemlere göre, farklılık gösteren sonuç ürünlerin istatikselsel ve görsel analiziyle birlikte, yüksek doğrulukta tematik harita üretiminde dikkat edilmesi gereken tüm detaylar vurgulanmıştır. Sonuçlar bölümünde, önerilen yöntemin başarısı irdelenmiş, tüm tez çalışması özetlenmiş ve sonuç ürünlerin altlık veri sağlayabileceği olası çalışma alanları ve gelecek tarihli çalışmalar hakkında önerilere yer verilmiştir.



**Şekil 1.1:** Çalışma yapısına ait genel başlıklar.

## 2. LİTERATÜR ÇALIŞMASI

Uzaktan algılamanın yeryüzünün gözleminde, değişimlerin tespitinde ve analizinde son derece etkin bir araç olduğu birçok çalışma ile kanıtlanmıştır [Bufebo and Elias, 2021], [Mashala et al., 2023], [Kuenzer et al., 2014]. Uydu teknolojilerinin ortaya çıkışıyla uydu tabanlı uzaktan algılama belirli bir zaman ve konumda AÖ/AK'ya ilişkin bilgi sağlama yeteneği sayesinde devrim yaratmıştır ve ortaya çıkışını takip eden yıllarda son derece popüler bir kaynak olacağı öngörülmüştür [Steiner, 1965], [Attri et al., 2015]. Yeryüzüne ait havadan alınmış ilk görüntü bir sıcak hava balonuyla 1858 yılında Nadar tarafından alınmıştır. Sonraki yıllarda güvercin ve uçurtmalar gibi çeşitli kaynaklar da denenmiş, yeryüzünün gözlemi için ilk sivil amaçlı optik uydu olan Dünya Kaynakları Teknoloji Uydusu (Earth Resources Technology Satellite, ERTS) 1972 yılında Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration, NASA) tarafından fırlatılmıştır. Sonrasında LANDSAT olarak adlandırılmış ve 2013 yılına kadar devam eden süreçte son olarak LANDSAT-9 olmak üzere dokuz farklı uydunun üretimi tamamlanmıştır, güncel haliyle pankromatik 15 m ve MS 30 m mekansal, 16 günlük zamansal çözünürlüğe sahiptir. Günümüzde ise yaklaşık 0.30 m çözünürlük ile WorldView-3 uydusu en yüksek mekansal çözünürlüğe sahiptir. Ancak optik algılama sistemlerinin bulutluluk oranı gibi hava koşullarına bağlı değişkenlerden doğrudan etkilenmesi, zamansal çözünürlüklerinin düşük olması gibi dezavantajlar yeryüzünün gözlemlenmesinde kritik problemler oluşturmaktadır [Iizuka et al., 2018]. Aktif algılama sistemlerine sahip radar uyduları hava koşullarından bağımsız çalışabilirken verinin yorumlanabilirliği ve analizindeki kompleks yapı sebebiyle çeşitli dezavantajlara sahiptir [Richards, 2009]. Uyduların yanı sıra insanlı hava araçları ile gerçekleştirilen geleneksel fotogrametrik çalışmalar, hava durumuna bağlı engelleri ortadan kaldırmaktadır ancak uçuş maliyetinin çok fazla olması nedeniyle uygulanabilirliğini zorlaştırmaktadır [Matese et al., 2015]. Ancak spesifik çalışmalar için yetersiz kalan zamansal ve mekansal çözünürlük, bu teknolojilerin belirli amaçlar için ihtiyaç duyulan verilerin temininde kullanılamamasına sebep olmuştur. Böylelikle arka planda kalan uydu teknolojileri ve geleneksel fotogrametrik yöntemler yerini yüksek çözünürlüklü veri üretebilen modern İHA'lara bırakmıştır. İHA yüksek mekansal ve

zamansal çözünürlükle beraber ekonomik çözümler sunması sebebiyle, geleneksel hava fotogrametrisi ve uydu teknolojilerinin güçlü bir alternatifi olmuştur [**Kerle and Pfeifer, 2008**]. Van Blyenburgh İHA'ları insansız ve yeniden kullanılabilen motorlu hava araçları olarak tanımlamıştır [**Van Blyenburgh, 1999**]. İHA üzerinde Küresel Konum Belirleme Sistemi (GPS), İnersiyal Ölçme Ünitesi (Inertial Measurement Unit, IMU), kompas, otopilot gibi çeşitli bileşenleri bulunduran, uzaktan kontrol edilebilen, fotogrametrik amaçlı kullanıma uygun ve sıkça tercih edilen bir sistemdir. Bu temel bileşenlerin yanı sıra kullanım amacına göre değişkenlik gösteren LiDAR (Light Detection and Ranging), optik ve radar sensörlerle de modifiye edilebilmektedir.

Modern, ekonomik tüketici sınıfı İHA'lar görünür bölgedeki dalga boylarında (RGB) algılama sistemlerine sahiptir [**Eisenbeiß, 2009**]. Kullanım amaçlarına göre tercih edilirlerken kamera çözünürlüğü, odak uzaklığı, CMOS algılayıcı kalitesi ve piksel büyüklüğü bilgileri dikkate alınmaktadır. RGB sensörlere ek olarak çok bantlı İHA'lar da çok sayıda bilimsel çalışmada tercih edilmektedir. Ancak yüksek maliyetleri sebebiyle RGB İHA'larla kıyaslandığında kullanım yaygınlığı çok daha azdır [**Yao et al., 2019**]. Görüntü formatlarının değişkenlik göstermesi ve fotogrametrik amaçlı kullanım için satıcı firmaların kar amaçlı politikaları nedeniyle sağladıkları donanımlara ek paket yazılımlar sunmaları ve bunlara bağlı kalınması zorunluluğu da bir diğer dezavantajdır. MS İHA'lar kırmızı kenar, yakın kızılötesi gibi bantlarla beraber geniş spektral aralıkta veri kaydedebilme avantajları sayesinde klorofil analizi, bitki sağlığı gözlemi, yabancı ot tespiti gibi tarımsal uygulamalarda sıkça tercih edilmektedirler [**Simic Milas et al., 2018**], [**Bah et al., 2018**].

Yao et al., hazırladıkları derleme çalışmasında İHA'nın bu gibi avantajlarının yanı sıra gelişmiş sensörlerinin uzaktan algılamanın AÖ tespiti, tematik harita üretimi, değişim analizi gibi spesifik konularına yönelik çözümlerinin yeterli sistematik analizinin bulunmadığını belirtmişlerdir. Yüksek çözünürlük kavramının ortaya çıkışıyla (10 cm'den düşük) arazi örtüsü sınıflandırmasında araç, yaya gibi istenmeyen sınıflar meydana gelmekte ve fotogrametrik görüntülerin geometrik ve spektral analizi için daha gelişmiş tekniklere ihtiyaç duyulmaktadır [**Yao et al., 2019**]. Birçok çalışma İHA'nın sahip olduğu karakteristik özellikleri göz ardı ederek geleneksel uzaktan algılama verilerinde kullanılan tekniklerle üretim gerçekleştirmektedir. Yakın mesafeden koordinatlı görüntü alımı, sahip olunan zengin spektral bilgi ve paket yazılımların kullanımıyla üretilen yüksek doğrulukta DYM, DAM ve NDYM gibi

3B veriler ön planda tutularak, sınıflandırma işleminin başarı oranında artış sağlanabilmektedir.

Görüntülerin değerlendirilebilir hale gelmesi amacıyla öncelikli olarak fotogrametrik bir iş akışına tabi tutulmaları gerekmektedir. Fotogrametri, görüntülerin üzerinde ölçüm yapılabilir ve yorumlanabilir hale getirilmesidir ve uzaktan algılama alanının bir parçasıdır [Linder, 2013]. İnsan gözünün nesnelere 3B olarak algılaması esasına dayanarak geliştirilen stereo bakış yöntemi ile bir nesnenin farklı bakış açılarından alınan iki ya da daha fazla görüntüsünün, 3B model oluşumunun ve koordinat bilgisinin elde edilmesine olanak sağlamaktadır. Fotogrametrinin tarihsel süreci incelendiğinde, gelişiminde üç ana dönemin olduğu görülmektedir. Öncelikle yöneltme olarak tanımlanan, görüntü üzerinde yer alan bir noktanın arazi yüzeyindeki izdüşümünün konumlandırılması işlemi gerçekleştirilmedi. Bu işlem Analog Fotogrametri olarak adlandırılan dönemin ilk yıllarında büyük boyutlu, karmaşık yapıları, tamamen optik-mekanik cihazlar ile gerçekleştirilmektedir ve tecrübeli bir operatör ihtiyacı bulunmaktadır. Bilgisayarların ortaya çıkışı, bu süreçte farklı bir dönemi beraberinde getirmiştir. Yöneltme işleminin analog yöntemlerle uygulanmasının yerine değişkenlerin belirlenip, formüllere entegre edildikten sonra bilgisayar ortamında depolanıp, hesaplamaların gerçekleştirildiği Analitik Fotogrametri dönemi şekillenmeye başlamıştır. Bu dönemde fotogrametrik kıymetlendirme çok daha küçük boyutlu, ekonomik ve kullanımı kolay cihazlarla yürütülmektedir. Ancak hala görüntüler yerine, fotoğraflar üzerinde optik ve mekanik sistemlerin kullanımı söz konusudur [Linder, 2013]. Günümüzde ise bilgisayar teknolojilerindeki yüksek hızlı gelişim, fotoğraf kavramının yerini dijital görüntüye bırakmasına olanak sağlamıştır. Gelişmiş teknolojileri, depolama ve işleme kapasiteleriyle günümüz bilgisayarları operatör ihtiyacını minimum düzeye indirmiş ve iş akış sürecini yüksek oranda otomatikleştirmiştir. Dönemin ilk yıllarında dijital fotoğraf kameralarının maliyeti ve çok sayıda arşivlenmiş fotoğrafın bulunması nedeniyle öncelikli olarak tarayıcı cihazlar tercih edilmiş ve dijital görüntüler bu cihazlar yardımıyla oluşturulmuştur. Ekonomik dijital kameralara ulaşımın sağlanabildiği yıllarla birlikte dijital görüntü kavramı hayatımızın bir parçası haline gelmiştir.

Fotogrametrik ürünlerin değerlendirilmesinde ise makine öğrenmesi algoritmaları yüksek boyutlu verilerle, lineer ve lineer olmayan problemlerin çözümündeki kabiliyetleriyle önemli bir role sahiptir [Eskandari et al., 2020]. Genellikle sınıflandırma, kümeleme, regresyon gibi çalışmalar, makine öğrenmesinin görüntü destekli çalışmalarında temel kullanım alanlarını oluşturmaktadır [Banerjee et al., 2022], [Bithas et al., 2019]. Su kaynaklarının yönetimi, mineral ve sulak alan analizi gibi birçok problemin çözümünde sınıflandırma algoritmalarından yararlanılması bu alanı en yaygın kullanılan yöntem haline getirmiştir [Mahdianpari et al., 2017], [Lovitt et al., 2017]. Sınıflandırmanın yaygın kullanımı, temelinde çalışan algoritmaların geliştirilmesi ya da yardımcı verilerin entegre edilmesi ihtiyacını ortaya çıkarmıştır.

Modica et al., 2021 yılında gerçekleştirdikleri çalışmalarında çok bantlı İHA verisi ve makine öğrenmesi algoritmaları kullanarak soğan ve narenciye bahçelerini içeren obje tabanlı bir sınıflandırma işlemi gerçekleştirmişlerdir. Sınıflandırıcı olarak KNN, SVM, RF, Naive Bayes (NB) uygulanmış ve sonuçları karşılaştırmalı olarak McNemar testi ile analiz edilmiştir. Segmentasyon için Large Scale Mean-Shift, Shepherd ve çoklu çözünürlük segmentasyon olmak üzere üç farklı yazılım ve algoritma denenmiştir. RF ve SVM tercih edilen programlardan ve çalışma alanından en az etkilenen sınıflandırıcılar olmuş ve soğan bahçelerinde %90'nın üzerinde sınıflandırma doğruluğuna ulaşmışlardır. Spektral bilgiye ek olarak DYM'nin ek veri olarak değerlendirildiği bu çalışmada narenciye bahçelerinin analizinde önemli bir doğruluk artışı sağlanmıştır. Yüksek çözünürlüklü DYM'nin bitki boyunun ölçümünde etkili olduğu, ağaç ve bitki sınıfının ayrımını kolaylaştırdığı belirtilmiş ancak otomatik üretilen DYM'nin yoğun ağaçlı alanlarda çimler üzerinde bozucu etki oluşturduğu belirtilmiştir [Modica et al., 2021].

Zisi et al., çok bantlı İHA verisi ile üretilen DYM ve spektral bilgiyi yardımcı veri olarak değerlendirerek deve diken bitkisinin haritalandırılmasında performans arttırımı hedeflemiştir. 2015 yıllı görüntülerin kullanımıyla, doku ve DYM'den elde edilen yükseklik bilgisinin katman olarak eklendiği veri setiyle genel sınıflandırma doğruluğunda %17 (%70-87), 2016 yıllı verinin değerlendirilmesinde ise %13 (%82-95) oranında bir artış elde edilmiştir. Çalışmalarında doku ve yükseklik bilgisinin eşit oranda katkı sağladığından bahsetmişler ve buna sebep olarak bitki yüksekliklerindeki geçişlerde oluşan gölgelerin yükseklik verisi ile uyumlu hareket göstermesi yani

kullanılan algoritmaların bu bölgelerdeki spektral geçişle beraber yükseklikteki değişimi eşit ölçüde değerlendirdiğinden bahsetmişlerdir [**Zisi et al., 2018**].

De Castro et al., çalışmalarında MD4-1000 yeşil, kırmızı, yakın kızılötesi bantlara sahip İHA ile elde ettikleri verileri Agisoft PhotoScan Professional yazılımında değerlendirerek DYM ve ortomozaik üretimi gerçekleştirmişlerdir. Bu veriler yardımıyla obje tabanlı görüntü analizi yöntemi kullanarak, yabancı otların tespitini amaçlamışlardır. Yöntem eCognition Developer 9 yazılımı üzerinden DYM ve ortomozaik verilerinin girdi olarak kullanılmasıyla uygulanmıştır. DYM verisi çoklu çözünürlük segmentasyon yöntemi ile segmentlere bölünmüş, deniz yüzeyinden olan minimum yükseklik zemin kotu olarak kabul edilmiş ve mahsullerin boy çıkarımı gerçekleştirilmiştir. Sonrasında RF yöntemi mahsullere ait boy ve spektral bilgi ile eğitilmiş ardından yükseklik tahmini için kullanılmıştır. Ayçiçeği bitkisinin tahmininde pamuk bitkisine göre daha yüksek doğruluk sağlandığı görülmüş buna sebep olarak pamuk bitkisinin sulama sistemleri için arazi yüzeyinde meydana gelen değişimlerin etkisi olduğu belirtilmiştir [**De Castro et al., 2018**].

Husson et al., su üstü bitkilerin tespiti için İHA verisi tabanlı ortomozaik ve DYM üretimi gerçekleştirmiştir, doku ve spektral bilgilere ek olarak bu verinin bitkilerin çıkarımında fayda sağlayacağı hipotezini öne sürmüştür. DYM üretiminde Photoscan yazılımı destekli, SFM algoritmasıyla elde edilen nokta bulutundan otomatik üretim gerçekleştirmişlerdir. Objeye tabanlı görüntü analizi ve RF yöntemi kullanarak gerçekleştirdikleri sınıflandırma işleminde, beş farklı çalışma alanında büyüme düzeyinde genel doğruluk %78-87 arasında değişkenlik gösterirken baskın taksonlarda %65-85 arasında olduğu görülmüştür. Spektral ve doku bilgisinin yanı sıra yükseklik bilgisinin eklenmesi ile büyüme seviyesindeki bitkilerde %4-21 oranında baskın türlerde ise %3-30 arasında doğruluk artışı elde edilmiştir. Yükseklik bilgisinin etkili olduğu alanlar ise kompleks yapıları vejetasyon bölgeleri olmuştur ve sınıflandırma amaçlı çalışmalarda son derece etkili olduğu belirtilmiştir [**Husson et al., 2017**].

Guo et al., gerçekleştirdikleri kentsel ağaç sınıflandırması çalışmalarında çok bantlı İHA verisi kullanmış ve türler arası ayrımı amaçlayan obje tabanlı analiz ile RF algoritmasının kombinasyonunu içeren bir yaklaşım sunmuşlardır. Segmentasyon işlemi için çoklu çözünürlük segmentasyon yöntemi ve parametrelerin seçiminde ölçek parametresi belirleme aracı (ESP) kullanılmıştır. Sınıflandırma işlemi için RF,

SVM ve KNN algoritmalarını tercih etmişlerdir. Spektral özellikler, indeks, doku ve geometrik özellikleri kullanarak oluşturdukları dokuz farklı veri setinde RF algoritması, dokuzuncu veri setinde %91.89 genel doğrulukla üstün başarı göstermiştir. Bu veri seti tüm özelliklerin dahil edildiği ve özyinelemeli özellik seçimi (recursive feature elimination) algoritması ile belirlenen özellikleri içermektedir. Önerilen yöntem, çoğu ağaç türü için başarılı olsa da Kafur ağacı ve Japon tarçını türlerinin ayrımında düşük performans göstermiştir. Farklı boyutlara sahip bu türlerin ayrımında, yükseklik bilgisine ihtiyaç duyulduğu ve kullanımının sınıflandırma sonucunda etkili olacağı belirtilmiştir [Guo et al., 2022].

Amorim et al., çok bantlı İHA ile buğday bitkisinin dönemlik biyokütle analizini ve tahminini içeren bir çalışma gerçekleştirmiştir. Çalışmalarında İHA'dan temin edilen görüntülerle vejetasyon indisi hesabı gerçekleştirmiş ve buna dayalı biyokütle analizi için regresyon modelleri kurmuşlardır. Model oluşturmada RF, SVM ve Yapay Sinir Ağlarından (YSA) faydalanmışlardır. 0.90 korelasyon değeriyle en iyi tahmin sonucu veren model YSA olarak belirlenmiştir. Gelecek çalışmalarda LiDAR, DAM ve DYM gibi yükseklik bilgisine sahip verilerin biyokütle tahmini için yüksek potansiyele sahip olduğuna dair çıkarımlarda bulunmuşlardır [Amorim, 2022].

Mollick et al., çalışmalarında AÖ/AK haritası üretimi amacıyla çok bantlı İHA verisi ve makine öğrenmesi algoritmalarını kullanmıştır. Üretimde piksel ve obje tabanlı her iki yöntem de denenmiş ve sonuçları karşılaştırmalı olarak analiz edilmiştir. Obje tabanlı sınıflandırma işlemi için KNN, piksel tabanlı sınıflandırma içinse Maksimum Olabilirlik yöntemleri kullanılmıştır. Bunlara ek olarak kontrolsüz sınıflandırma işlemi gerçekleştirilmiş ve piksellerin kümelenmesi için K-ortalamlar kümeleme yöntemi denenmiştir. Obje tabanlı üretilen tematik haritaların piksel tabanlıya göre genel doğruluk değerinde %21 daha yüksek, Kappa değerinde ise %27 oranında daha iyi sonuçlar gösterdiği belirlenmiştir. Yüksek çözünürlüklü İHA verisi ile gerçekleştirilen çalışmada, obje tabanının piksel tabanlıya göre üstün performans gösterdiğini ifade etmişlerdir. Bunu yanı sıra DYM kullanımının pozitif ve negatif etkilerini; değişken yüksekliğe sahip objelerin ayrımını sağlarken eş yükseklikteki zemin noktalarının aynı AK sınıfına atanması gibi bir problem oluşturduğu şeklinde dile getirmişlerdir [Mollick et al., 2023].

Park et al., kentsel alan için gerçekleştirdikleri AK haritalandırma çalışmasında çok bantlı İHA ile dokuz farklı nitelikteki ortomozaik (mavi, yeşil, kırmızı, kırmızı-kenar, yakın kızılötesi, yüzey sıcaklığı, NDVI, SAVI, NDYM) veriden elde ettikleri 126 özelliğin sınıflandırma sonucundaki etkilerini analiz etmişlerdir. Sınıflandırıcı olarak RF yöntemi kullanılarak tüm özelliklerin girdi olarak sunulmasının yanı sıra özellik seçimi ile RF optimize edilmiş ve daha az sayıdaki değişkenle üretilen tematik haritalar da analiz edilmiştir. Özelliklerin etkisinin analizi sonucunda sırasıyla NDYM, NDVI, yüzey sıcaklığı, SAVI, mavi, yeşil, kırmızı, kırmızı kenar en yüksek ağırlık değerine sahip olmuştur. NDYM verisinin özellikle çimen, ağaç ve bina yapıları arasında sınıf ayrımını kolaylaştırdığı ve RF algoritmasının optimizasyonu ile değişken azaltımı sonucunda ise tematik harita sonuçlarında önemli bir değişim olmadığı ifade edilmiştir [Park et al., 2022].

Vanhuyse et al., çalışmalarında yüksek çözünürlüklü WorldView-3 verisi kullanarak obje tabanlı kentsel AÖ haritalandırma işlemi gerçekleştirmişlerdir. Stereo bakış geometrisine dayalı olarak elde edilen ve değerlendirilen görüntülerle 3B model oluşturulmuş ve DYM için altlık olarak kullanılmıştır. DAM üretimi içinse Geomatica 2015 yazılımının sağladığı arazi filtresinden faydalanılmıştır. Son olarak iki modelin farkı alınarak NDYM verisinin üretimi tamamlanmış ve WorldView-3 görüntüsüne entegre edilerek AÖ sınıfı tespitinde değerlendirilmiştir. Sınıflandırma işleminde RF yöntemi uygulanmış, özellikle ağaç, bina ve toprak zemin sınıflarının ayrımında NDYM verisinin etkisinin ön plana çıktığı belirtilmiştir [Vanhuyse et al., 2017].

Al-Najjar et al., RGB İHA ile gerçekleştirdikleri AÖ tespiti çalışmasında, sınıflandırma doğruluğunu arttırmayı hedeflemiş ve Evrişimli Sinir Ağları yöntemini kullanmışlardır. Bu amaç doğrultusunda İHA tabanlı veriyle Agisoft ortamında otomatik üretilen DYM verisi, yardımcı veri olarak eklenmiş ve sınıflandırma doğruluğu üzerindeki etkisi irdelenmiştir. Tematik haritaların doğrulukları incelendiğinde genel doğruluk 0.98, Kappa değeri 0.98 olarak elde edilmiştir. DYM verisinin genel doğrulukta %1.2, Kappa değerinde ise %1.5 oranında doğruluk artışı sağladığı belirlenmiştir. Yükseklik bilgisinin olmadığı durumda yoğun vejetasyon alanlarında kısa bitki ve ağaç, çıplak arazi ile bina yapılarının yanlış sınıflandırıldığından bahsedilmiştir [Al-Najjar et al., 2019].

Iizuka et al., yapay açıklıklı radar (Synthetic Aperture Radar, SAR) ve İHA kullanımıyla gerçekleřtirdikleri AÖ/AK haritalarının üretimi çalışmasında, her iki sistemin avantajları ve dezavantajları üzerine arařtırmalar gerçekleřtirmiřtir. PALSAR-2 ve DJI Phantom 4 cihazlarından temin ettikleri veriler ile iki farklı bölge için yapay sinir ađları ile sınıflandırma gerçekleřtirerek AÖ/AK tematik haritaları üretilmiřtir. SAR ile sınıflandırmada geniř ölçekli alanlar için kabul edilebilir dođruluklar elde edilirken küçük yüzölçümüne sahip bölgelerde İHA'nın oldukça tatmin edici sonuçlar ürettiđine değinmiřlerdir [**Iizuka et al., 2018**].

Chauhan et al., yüksek çözünürlüklü İHA verisi ile kentsel altyapı çıkarımı çalışmalarında obje tabanlı görüntü analizi ve çoklu çözünürlük segmentasyon yöntemiyle bina, yol vb. unsurların otomatik çıkarımını sađlayan bir iř akıřı sunmayı amaçlamıřtır. Görünür bölgede algılama yapan 42 megapiksel çözünürlüđe sahip Sony Alpha R II monte edilmiř İHA ile görüntü alımı gerçekleřtirilmiřtir. Zemin ve zemin üstü noktaların tespiti için otomatik üretilen DYM, binaların tespiti içinse NDYM ve bu modele bađlı belirlenen eřik değeri kullanılmıřtır. Kural tabanlı gerçekleřtirilen sınıflandırmada 2.5 m üstü boyuta sahip nesnelere bina olarak değlendirilmiř ancak bu boyutlardaki ađaç vb. unsurları içeren sınıflarda yanlış sınıflandırmalar oluřmuř ve önüne geçmek için geometrik özelliklere dayanan ekstra eřik değeri belirlenmiřtir. Bina ve yol sınıflarının referans vektör veri ile karřılařtırılması sonucunda sırasıyla %98 ve %85.8 oranında dođruluk elde edilmiřtir. Önerilen metodolojinin kentsel özellik çıkarımı için umut verici sonuçlar ortaya koyduđunu ve küçük deđişikliklerle farklı çalışma alanlarına da uygulanabilirliđinin mümkün olduđunu iddia etmiřlerdir [**Chauhan et al., 2022**].

Sigdel, çalışmasında gecekonduların yoğun olduđu bir bölge özelinde bu yapıların yasal kořullarla yapılmıř binalardan ayrımını hedefleyen bir sınıflandırma çalışması gerçekleřtirmiřtir. Uydu görüntülerinin sađladıđı çözünürlüđün bu ayrımı yapmakta yetersiz kaldıđı ve İHA'nın bu noktada alternatif bir çözüm sunduđu belirtilmiřtir. İki farklı sınıftaki bina yapıları benzer spektral ve doku özelliklerine sahipken aralarındaki yükseklik farkı, ayrımları için önemli bir deđiřkendir. Bu nedenle ortomozaik ya da ortomozaige ek olarak DYM'nin kullanıldıđı çalışmalara kıyasla NDYM ve vejetasyon indislerinden faydalanılmıřtır. Derin öğrenme algoritmaları ile gerçekleřtirilen sınıflandırma sonuçlarının analizinde, referans ile model çıktıısındaki

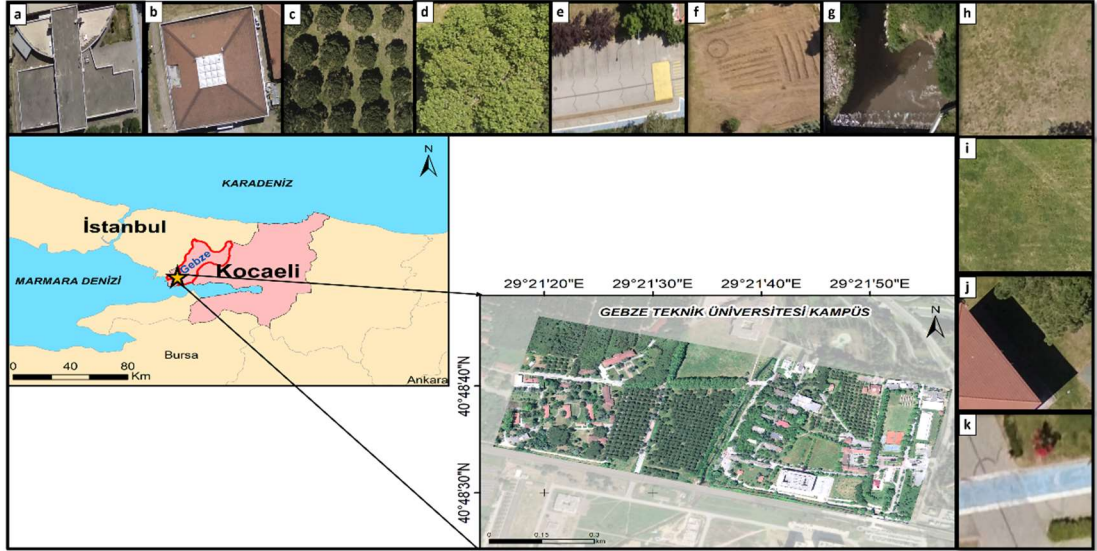
örtüşme oranını esas alan IoU (Intersection over Union) yöntemi kullanılmıştır ve NDYM'in %77.9'luk IoU oranında %6 artış sağladığı ifade edilmiştir [Sigdel, 2021].

Belcore et al., çalışmalarında taşkın riski bulunan alanların tespiti için AÖ haritasının üretimini gerçekleştirmiştir. Görünür bölgeye ek olarak yakın kızılötesi bant içeren iki farklı kamera montelenmiş İHA ile veri temin edilmiştir. Farklı sensörlere sahip kameralara ait veriler Agisoft Metashape Professional yazılımında ayrı ayrı işlenmiş ve iki adet ortomozaik üretimi gerçekleştirilmiştir. DYM üretiminde daha yüksek çözünürlüğe sahip RGB kameranın verisi değerlendirilmiştir. Zemin noktalarının seçimi Metashape yazılımıyla otomatik olarak gerçekleştirilmiş ve DAM üretilmiştir. DYM'nin ve DAM'ın üretiminin ardından model farkları alınarak NDYM elde edilmiştir. Bina sınıfının belirlenmesinde 4 m üstü ve komşu yapılarla yükseklik farkının 0.2 m olması koşulları belirlenmiştir. Sınıflandırıcı olarak RF yöntemi kullanılmıştır. Binalar %84 oranında doğru bir şekilde tespit edilmiştir ve yükseklik verisinin sonuç performansında doğrudan etkili olduğu belirtilmiştir [Belcore et al., 2022].

Kapsamlı bir şekilde gerçekleştirilen literatür araştırması neticesinde, multispektral İHA'ların kentsel özelliklerin çeşitlilik gösterdiği çok sayıdaki AÖ/AK sınıfını içeren bölgelerde, performansının yeterince incelenmediği ve bunun yanı sıra yükseklik verisinin yardımcı kaynak olarak kullanıldığı durumlarda 3B modellerin oluşum sürecinde yalnızca otomatik üretimin esas alındığı, paket programlara bağlılığın söz konusu olduğu görülmüştür. Bu noktada yüksek doğrulukta üretilen ve sınıflandırma sonucuna etkisinin makine öğrenmesi desteğiyle detaylı bir şekilde irdelendiği NDYM ve çok sayıdaki indeksin yer aldığı sınıflandırma çalışmamın, AÖ/AK haritalarının üretimi alanında literatürde önemli bir yere sahip olacağı öngörülmektedir.

### 3. ÇALIŞMA ALANI

Çalışma alanı Kocaeli ili Gebze ilçesi sınırları içerisinde yer alan Gebze Teknik Üniversitesi kampüsünün kuzey bölümünde yer almaktadır. Bölge Marmara Denizi'ne komşu olmakla birlikte deniz seviyesinden yaklaşık 10 m yukarıda konumlanmakta ve geneli düz olarak nitelendirilebilecek topografik özellikler göstermektedir. Çalışma bölgesi sahip olduğu 36 hektarlık geniş yüzölçümü ile yeşil alan ve su geçirimsiz alan gibi temel sınıf başlıkları altında beton çatı (a), kırmızı çatı (b), iğne yapraklı ağaç (c), geniş yapraklı ağaç (d), yol (e), toprak (f), su (g), seyrek bitki örtüsü (h), yoğun bitki örtüsü (i), gölge (j) ve bisiklet yolu (k) olmak üzere 11 farklı sınıf bilgisini içermektedir Şekil 3.1 (a-k).



Şekil 3.1: Gebze Teknik Üniversitesi kampüs alanı ve AÖ/AK sınıfları (a-k).

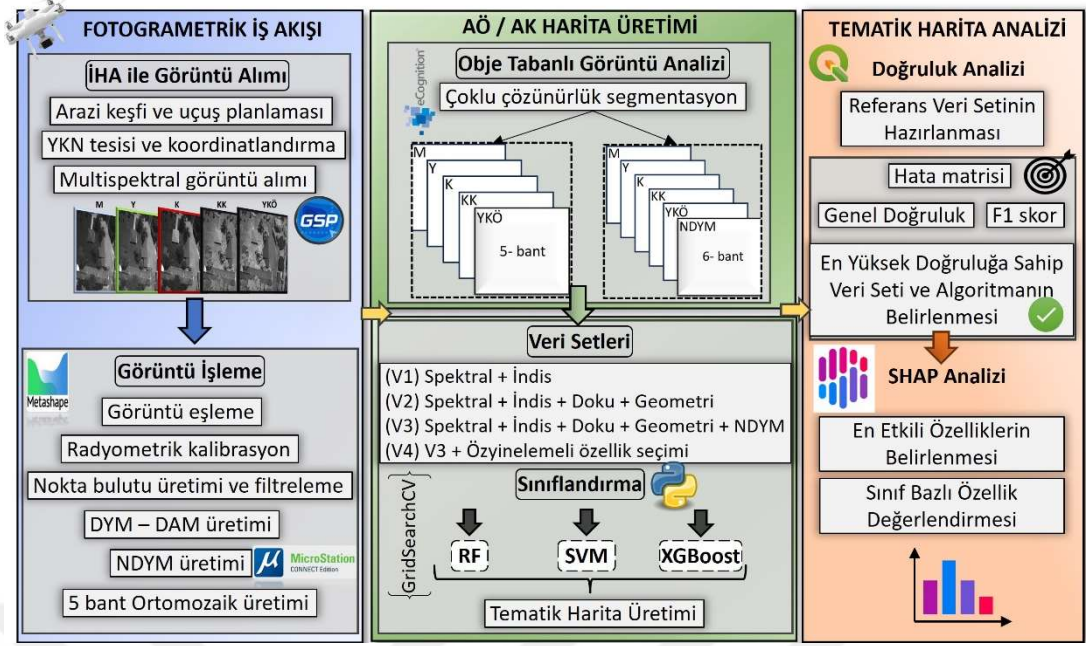
Sınıf etiketlerinin belirlenmesi, kapsamlı bir şekilde gerçekleştirilen arazi keşfi ile tamamlanmıştır. Beton çatı sınıfı, özellikle yol sınıfı ile çok yüksek spektral benzerliğe sahip gri ve beyaz çatılı yapıları temsil ederken kırmızı çatı sınıfı, kiremit yapılı ve benzer renkli bina yapılarını içermektedir. İğne yapraklı ağaç sınıfı, fıstık çamı ve kızılçam gibi ağaçları temsil ederken, geniş yapraklı ağaç sınıfı ise karakavak ve çınar ağacı türlerini kapsamaktadır. Su geçirimsiz zemin kotlu beton yapılı alanlar yol sınıfı olarak adlandırılmıştır. Bitki örtüsünden yoksun doğal yapılı alanlar toprak sınıfını oluştururken, yeşil alan yoğunluğuna bağlı olarak seyrek ve yoğun olmak üzere iki

farklı bitki örtüsü sınıfı tanımlanmıştır. Seyrek bitki örtüsü, bölgesel olarak bitki örtüsüne sahip, geneli toprak olan alanları temsil ederken, yoğun bitki örtüsü tamamı çimen vb. düşük kotlu yeşil alanlar ile kaplı bölgeleri ifade etmektedir. Su birikintisine sahip akarsu ve havuzlar su sınıfını oluşturmaktadır. Bu sınıfların yanı sıra yüksek çözünürlüklü üretilen tematik haritalarda yanlış sınıflandırmalara sebep olan, doğal ya da yapay objelerden kaynaklanan gölge alanlar da gölge sınıfı olarak tanımlanmıştır.



## 4. METODOLOJİ

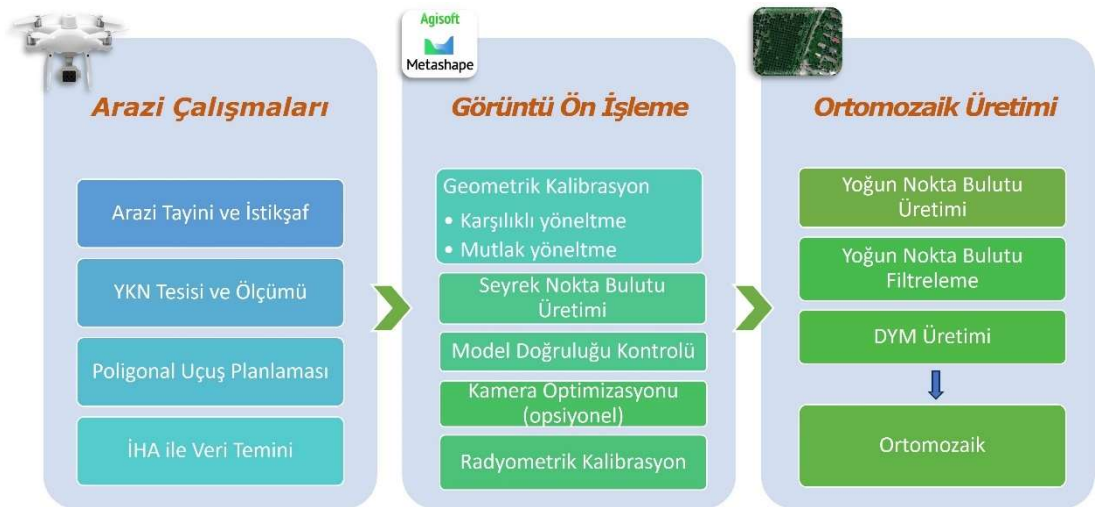
Tez kapsamında gerçekleştirilen çalışmalar, veri alımı, AÖ/AK haritalarının üretimi, tematik harita analizi olmak üzere üç ana hedef doğrultusunda ilerlemiştir **Şekil 4.1**. Yardımcı verilerin kombinasyonu ile oluşturulan dört farklı veri seti için tüm işlem adımları uygulanmış ve çeşitli yaklaşımlar neticesinde üretilen çıktıların görsel ve istatistiki analizleri tamamlanmıştır. Öncelikli olarak DJI Phantom 4 Multispektral İHA ile görüntü alımı ardından görüntü işleme adımları uygulanmıştır. Görüntü işleme sürecinde, temin edilen görüntülerden DYM, DAM, NDYM ve ortomozaik gibi fotogrametrik ürünlerin üretimi gerçekleştirilmiştir. Üretilen 5-bantlı ortomozaik ve bu altlığa eklenen raster formatlı NDYM verisiyle tasarlanan 6-bantlı görüntü, obje tabanlı çoklu çözünürlük segmentasyon yönteminde bağımsız olarak değerlendirilmiş ve iki farklı segmentasyon sonucu elde edilmiştir. İHA tabanlı entegre yaklaşımla üretilen her iki altlık dört farklı veri seti (V1, V2, V3, V4) ve RF, SVM, XGBoost olmak üzere üç farklı makine öğrenmesi algoritması yardımıyla sınıflandırma işlemine tabi tutularak 11 farklı AÖ/AK sınıfını içeren tematik haritalar üretilmiştir. Son adımda, sınıflandırma sonucu üretilen tematik haritaların doğruluk analizi, en yüksek performanslı veri seti ve algoritmanın belirlenmesi işlemleri gerçekleştirilmiştir. En yüksek doğrulukla üretilen tematik harita için tüm özelliklerin sınıflandırma işlemi üzerindeki etkisi SHAP algoritması yardımıyla incelenmiştir ve en yüksek etkiye sahip özellik belirlenmiştir. Buna ek olarak özellik etkilerinin sınıf bazlı değerlendirmesi yapılmış ve sonuçlar grafikler aracılığıyla yorumlanmıştır.



Şekil 4.1: Tez kapsamında uygulanan metodoloji.

## 4.1. Ortomozaik Üretiminde Fotogrametrik İşlem Adımları

İki boyutlu görüntülerden üçüncü boyuta geçiş ve çeşitli 3B ürünlerin elde edilmesi fotogrametrinin temel görevlerinden birisidir [Hartmann et al., 2016]. Ortomozaik, geometrik olarak düzeltilmiş hava fotoğraflarının birleşiminden oluşan, ölçekli bir harita gibi üzerinden metrik bilgi sağlanabilen fotogrametrik nihai üründür. İHA verileri ile ortomozaik üretiminin genel iş akışı Şekil 4.2’de sunulmaktadır.



Şekil 4.2: Ortomozaik üretiminde fotogrametrik iş akışı.

#### 4.1.1. İHA ile Görüntü Alımı

İHA'lar bilim dünyasında güncelliğini korumakta ve bu araçlardan temin edilen görüntüler hala çeşitli amaçlara hizmet etmektedir. Araştırma konusuna bağlı olarak ihtiyaç duyulan mekansal çözünürlük farklılık göstermekte ve buna bağlı olarak tercih edilen İHA, kamera donanımı, uçuş yüksekliği gibi bileşenler farklılık göstermektedir. Bu sebeplerden ötürü İHA kullanımında standart bir prosedür bulunmamakta ve ihtiyaç duyulan çözünürlük, çalışma bölgesi için mevcut güvenli uçuş alanı, hava koşulları, yüzölçümü vb. birçok unsur uçuş planının hazırlanmasında etkili olmaktadır. İHA uçuş planı üzerinde tanımlanan güzergah noktaları kolonları oluşturmakta ve kolon içerisinde yer alan şerit hat doğrultusunda görüntü alımı gerçekleştirilmektedir.

İHA kaynaklı görüntülerin işlenmesi sürecinde fotogrametrik yöntemler kullanılmakta ve görüntülerin değerlendirilebilmesi amacıyla ardışık ya da aynı bölgeyi temsil eden görüntüler arasında belirli bindirme oranlarının tanımlanması gerekmektedir. Bindirme oranı iki görüntü arasındaki örtüşen alanların yüzdesini ifade etmektedir ve enine ve boyuna olarak adlandırılan iki yönlü bir değişkendir. Boyuna bindirme uçuş doğrultusu boyuna alınan ardışık görüntüler arasındaki ortak alanı temsil ederken, enine bindirme kolonlar arasındaki örtüşme oranını ifade etmektedir.

Uçuş planı; bindirme oranı, uçuş yüksekliği, çalışma alanı sınırları, görüntü alım noktaları ve görüntü sayısı, uçuş hızı, görüntü alım modu gibi parametrelerin kontrolü ve tanımlanmasıyla gerçekleştirilmektedir. Uçuş yüksekliği İHA'nın kalkış yaptığı konumdan düşey yönlü uzaklığını ifade etmektedir. İrtifa ise deniz yüzeyinden olan ortalama düşey uzaklığa karşılık gelmektedir. Yükseklik arttıkça kapsanan alan artarken mekansal çözünürlük düşmektedir. Mekansal çözünürlük, iki komşu pikselin orta noktaları arasındaki mesafenin arazi üzerindeki karşılığını ifade eden yer örnekleme aralığı (YÖA) ile doğrudan ilişkilidir. YÖA, denklem 4.1'de yer alan uçuş yüksekliği (H), odak uzaklığı (f) ve kamera üzerindeki sensör boyutuna bağımlı piksel boyutu ( $\mu$ ) yardımıyla hesaplanmaktadır [He et al., 2012]. Uçuş yüksekliği kullanıcı tarafından kontrol edilebilmekte ve YÖA'nın belirlenmesinde önemli bir role sahiptir.

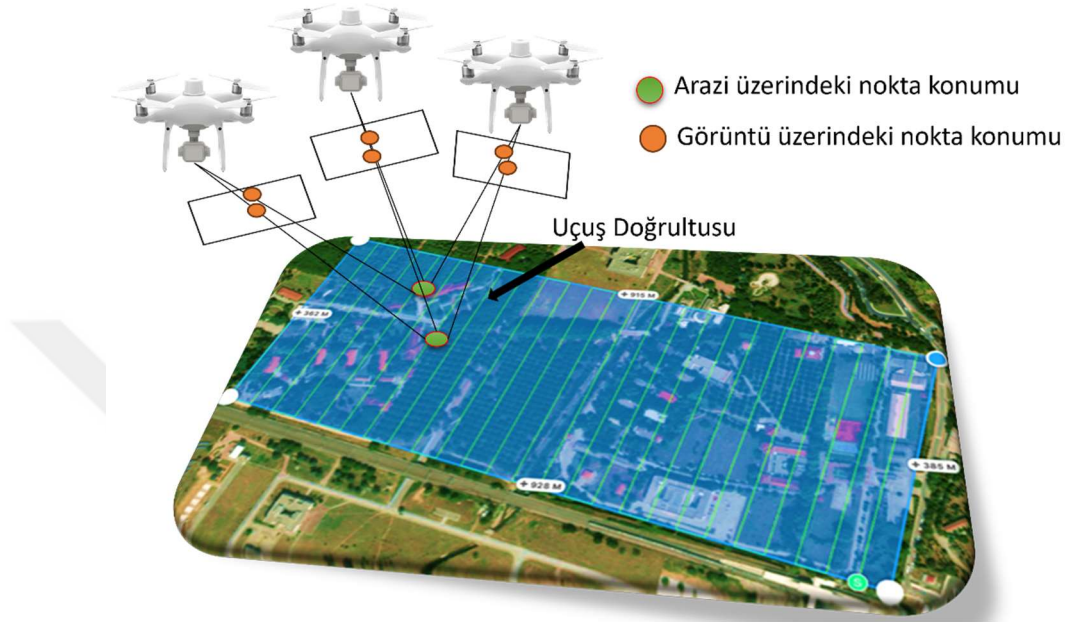
$$YÖA = \frac{H}{f} * \mu \quad (4.1)$$

Çalışmaya konu yapı ya da bölgeye bağlı olarak, otomatik uçuş desteği sağlayan yazılımlar aracılığıyla farklı görüntü alım planları uygulanabilmektedir. Tez kapsamında Ground Station Pro yazılımı aracılığıyla otomatik uçuş planı hazırlanmış ve uygulanmıştır. Örneğin 3B bir yapı için dairesel hareketle görüntü alım planı tercih edilirken, tarımsal uygulamalar için iki yönlü (kuzey-güney, doğu-batı) dur-çek modu önerilmektedir. Görüntü alım modlarının yanı sıra veri alımı için günün uygun saatlerinin tercihi, görüntü kalitesi için son derece önemlidir. Uçuş planlamasında, gölge alanların minimum seviyede, aydınlanma koşullarının ideal olduğu öğle saatlerinin tercih edilmesi gerekmektedir. Aydınlanma koşulları kontrast ve radyometrik doğruluk üzerinde doğrudan etki oluşturmaktadır. Görüntü alımı sonrası piksel değerleriyle ilişkili çeşitli metrikler yardımıyla görüntü kalitesi analizi gerçekleştirilmekte ve eşik değeri altında kalan görüntüler fotogrametrik işlem sürecine dahil edilmemektedir.

İHA ile çalışma alanına ait verilerin alınmasında: bölge sınırlarının belirlenmesi, uçuş planının hazırlanması, yer kontrol noktalarının (YKN) tesisi ve uçuş işlemleri sırasıyla gerçekleştirilmiştir. Görüntü alımında altı farklı sensör ile (R, G, B, RE, NIR, RGB) veri kaydedebilen DJI Phantom 4 Multispektral İHA kullanılmıştır. Özellikle kırmızı-kenar ve yakın kızılötesi bantları, bitki örtüsünün çıkarımında ve türler arası sınıflandırmada çeşitli indislerle üretilen değerlerle birlikte sınıflandırma sonuçlarına önemli katkılar sağlamaktadır [Lefebvre et al., 2019], [Pontoglio et al., 2021].

Görüntü alımı işleminin ardından kamera merceğinin doğasında bulunan distorsiyonların üretici firma tarafından sunulan parametreler ya da görüntülerin eşlenmesinin ardından hesaplanan parametreler yardımıyla giderilmesi gerekmektedir. SFM algoritması, farklı bakış açıları ile alınan hava fotoğraflarındaki ortak noktalar yardımıyla görüntü eşleme işlemini gerçekleştirmekte, tüm görüntü kümesini eş düzleme taşımakta ve kameraya ait bilinmeyenlerin hesaplanmasına olanak sağlamaktadır **Şekil 4.3**. Geleneksel fotogrametrik yöntemlerde noktaların 3B konumlarının belirlenmesi ve yöneltme işlemi için görüntü çekim anındaki kamera konumu ve koordinatları bilinen kontrol noktalarına ihtiyaç duyulmaktadır. SFM algoritmasının geliştirilmesiyle yalnızca görüntüler üzerindeki benzer spektral özellikteki pikseller kullanılarak görüntülerin yöneltme işlemi tamamlanabilmektedir. SFM algoritması, geleneksel fotogrametrik yöntemlerle kıyaslandığında görüntü alımı esnasındaki kamera konumunu daha yüksek doğrulukta tahmin edebilmekte ve

yöneltme işlemleri için ihtiyaç duyulan YKN sayısını azaltmaktadır [Zhang et al., 2023]. İHA verileri için SFM uygulanmasındaki esas amaç GPS ile elde edilen düşük doğruluklu konum verilerinin de işlem sürecine dahil edilmesiyle pozlama anındaki kamera konum bilgisinin yüksek doğrulukla elde edilebilmesidir.



**Şekil 4.3:** Bindirmeli alan içerisindeki noktaların farklı kamera bakış açıları ile görüntülenmesi.

Bindirme oranına bağlı olarak tek bir noktaya ait farklı bakış açılarından toplanan veri miktarı 3B uzayda noktanın doğru tasvirini kolaylaştırmaktadır. SFM algoritmasının genel iş akışında, öncelikli olarak her bir hava fotoğrafındaki spektral benzerlik gösteren anahtar noktalar ölçekten bağımsız özellik dönüşümü (scale invariant features, SIFT) gibi yöntemlerle çıkarılmakta ve bu noktalar görüntü çiftlerinin belirlenmesi amacıyla kullanılmaktadır. SIFT algoritması görüntü ölçekleme, döndürme ile değişmeyen, aydınlanma koşullarına karşı, görüntü üzerinde filtreleme işlemi ile keskin geçişleri yumuşatarak, minimum değişime sahip olan noktaların çıkarımını sağlamaktadır [Lingua, 2009]. SFM algoritması, tespit edilen bu noktalar yardımıyla bindirmeli alana sahip 2B görsellerin farklı bakış açılarından alınan görüntülerini kullanarak 3B geometriyi yüksek çözünürlükte yeniden oluşturabilme becerisine sahip, fotogrametri amaçlı çalışmalarda tatmin edici sonuçlar üreten bir yaklaşımdır [Westoby et al., 2012], [Ullman, 1979]. Nokta bulutu üretimi için belirli eşik değerleri içerisinde kalan en uygun görüntü çiftleri belirlenmekte, 2B ve 3B

bilgiler yardımıyla ışın demetleriyle dengeleme uygulanarak kamera konumu hesaplanmaktadır. Bu işlem tüm görüntü çiftleri için uygulanmakta ve elde edilen nokta kümeleri seyrek nokta bulutunu oluşturmaktadır. Son olarak IMU destekli temin edilen dönüklük parametreleri ve diferansiyel konum değerleri jeodezik koordinat sistemi ile ilişkilendirilir ve koordinat sistemi tanımlanmış 3B nokta bulutu yardımıyla DYM üretimi gerçekleştirilir. DYM ve hesaplanan yöneltme parametrelerine bağlı olarak her bir hava fotoğrafının rektifikasyonu gerçekleştirilmekte ve ortofoto haline getirilmektedir. Tüm ortofotoların mozaikleme işlemine tabi tutulması ve birleştirilmesiyle ortomozaik üretimi tamamlanmaktadır.

Günümüzde İHA'ların yaygın kullanımıyla birlikte ortomozaik gibi fotogrametrik ürünlerin üretimi önem kazanmış ve bu ihtiyaca karşılık olarak birçok modern ticari yazılım geliştirilmiştir. Agisoft, Pix4D, ContextCapture başlıca olmak üzere İHA teknolojilerine duyulan ilgi ve gelişen donanımları dikkate alınarak pratik arayüzlere sahip birçok ticari yazılım tasarlanmıştır. Tez kapsamında ortomozaik üretimine dair işlem adımlarının tamamı SFM tabanlı çalışan Agisoft Metashape Pro yazılımı aracılığıyla gerçekleştirilmiştir.


#### **4.1.2. Geometrik ve Radyometrik Düzeltme**

Ortomozaik üretimi için fotogrametrik süreç, görüntülerin alınması ve yöneltme işlemlerinin uygulanmasıyla başlamaktadır, İHA'dan alınan ham görüntüler geometrik ve radyometrik olarak düzeltilip yerel koordinat sistemleri ile ilişkilendirildikten sonra metrik bilgi sağlayan görüntüler haline gelmektedir. Ortofoto olarak adlandırılan bu görüntülerin birleşiminde bindirmeli alanlar kullanılmakta ve tüm çalışma alanını tasvir eden, mühendislik çalışmalarına uygun ölçekli bir görüntü elde edilmektedir.

Hava ve uzay kaynaklı temin edilen tüm görüntüler belirli miktarda radyometrik ve geometrik hatayı barındırmaktadır. Geometrik bozulmalar optik sistemlerin doğasında bulunan etkiler, yeryüzünün şekli gibi unsurlardan meydana gelmektedir. Bu etkiler sistematik hataları oluşturmakta ve rastgele hatalara göre çözümlenmeleri nispeten daha kolaydır. Rüzgar etkisi, teknik arıza, sarsıntı gibi kaynaklar rastgele hataları oluşturmaktadır. Geometrik düzeltme işlemi bu problemlerin çözümü amacıyla uygulanmaktadır ve piksellerin planimetrik olarak doğru bir şekilde konumlandırılmalarını sağlamaktadır.

Yüksek teknolojili optik sensörlere sahip dijital kameralar, geleneksel sensörlere göre ihmal edilebilir düzeyde mercek distorsiyonuna sahiptir [Turner et al., 2012]. Günümüzde İHA teknolojilerinin kullanıldığı birçok çalışmada kamera distorsiyonları ihmal edilmekte [Mathews, 2015] ve SFM tabanlı üretilen sonuç çıktıları üzerinden doğruluk analizleri gerçekleştirilmektedir. Rüzgar gibi rastgele hatalara sebep olan unsurlar ise gimbal olarak tanımlanan, kamera izdüşümünün korunması amacıyla ters yönlü kuvvet üreten iki ya da üç motorlu araçlar ile sağlanmaktadır.

GPS donanımına sahip İHA'lar ile yüksek konum doğruluğuna ulaşmak ve dış yöneltme işleminin gerçekleştirilmesi amacıyla çalışma alanı üzerinde tesis edilmiş YKN'lere ihtiyaç duyulmaktadır. DJI marka İHA Gerçek Zamanlı Kinematik (Real Time Kinematic, RTK) ekipmanına sahip olması sebebiyle GNSS istasyonuna bağlanarak, YKN tesisine ihtiyaç duymadan cm düzeyinde 3B konum doğruluğunu kullanıcıya sağlayabilmektedir. RTK donanımının mevcut olmadığı İHA'ların kullanımında ya da uçuş sırasında yaşanabilecek bağlantı problemlerine karşı ve uçuş işlemi sonrasında hassas georeferanslandırma, 3B modelin yüksek kalitede üretimi ve sonuç ürünün bağımsız denetim noktaları (BDN) yardımıyla doğruluk kontrolü için Şekil 4.4'te yer alan örnek YKN'ler tesis edilmektedir.



**Şekil 4.4:** YKN örnekleri: (a) yağlı boya ile tesis, (b) damalı tesis, (c) kireçli taş ile tesis, (d) mobil polikarbon tesis.

Çalışma amacına, bölge yüzölçümüne ve kullanılan veri alım aracına bağlı olarak mobil ya da sabit YKN'ler tercih edilmektedir. Periyodik veri temini gereken deformasyon analizi gibi çalışmalarda YKN'lerin çevresel etkilere karşı dayanıklılığı son derece önemlidir. Bu gibi tekrarlı ölçüm gerçekleştirilecek çalışmalarda daha korunaklı kalıcı tesisler gerekirken, 3B model üretimi gibi tek seferlik veri alımı gereken durumlarda mobil kontrol noktaları tercih edilmektedir. YKN seçiminde tesis edilecek yüzey rengi ve veri temini aracının mekansal çözünürlüğü göz önünde bulundurulmalıdır. Zemin rengiyle yüksek kontrasta sahip ve fotoğraflar üzerinde kolaylıkla ayırt edilebilir boyutta olmaları, farklı YKN türlerinin tercihinde önde gelen kriterler arasında olmalıdır. Tez kapsamında bu noktaların tesisinde; homojen dağılım, gölge alanlar, ağaç çevresi, araç trafiği, yükselti gibi unsurların problem teşkil etmesi sebebiyle bu vb. kriterler dikkate alınarak zemin kotlu açık alanlara tesis edilmelerine özen gösterilmiştir.

Geometrik hataların giderildiği fotoğraflar, fotogrametrik işlem sürecine dahil edilmekte ve SFM algoritması ile üretilen seyrek nokta bulutunun yeryüzü ile ilişkili mekansal çalışmalar için ihtiyaç duyulan koordinat bilgisine sahip olması amacıyla georeferanslandırma işleminin gerçekleştirilmesi gerekmektedir.

Georeferanslandırma, görüntü uzayının belirli bir koordinat sistemi ile ilişkilendirilmesi işlemidir. Bu işlem görüntü piksellerinin döndürülerek, ötelenerek, ölçeklendirilerek geometrik olarak doğru konuma getirilmelerini amaçlamaktadır [Frazier and Singh, 2021]. İHA ile alınan fotoğraflar için georeferanslandırma işlemi iki farklı iş akışı ile gerçekleştirilebilmektedir. İlk yöntemde İHA üzerinde yer alan GPS alıcısından ya da yüksek konum doğruluğu sağlayabilen RTK donanımı aracılığıyla fotoğrafların metaverisine kaydedilen koordinat bilgilerinden faydalanılırken **Şekil 4.5**, ikinci yöntemde hassas ölçümlerle temin edilmiş YKN koordinatları kullanılmaktadır.

GPS Altitude	: 158.9 m Above Sea Level
GPS Latitude	: 40 deg 48' 32.61" N
GPS Longitude	: 29 deg 21' 48.84" E

**Şekil 4.5:** Metaverisi içerisinde yer alan GPS koordinatları.

Her iki yöntem sonucunda üretilen ürünlerin değerlendirilmesi ve belirli doğruluk hedeflerinin sağlanması gerekmektedir. Fotogrametrik ürünlerin doğruluk kontrolü arazi koordinatlarının temin edilmesi ve 3B bu koordinatların sonuç ürünlerle ilişkilendirilmesiyle gerçekleşmektedir. YKN'ler görüntü üzerinde ve gerçek arazide yer alan koordinatlı noktalar olmaları sebebiyle referans veri niteliği taşımakta ve doğruluk analizinde yaygın olarak kullanılmaktadır. YKN'lerin dağılımı hem modelin üretim doğruluğu hem de üretilen modelin doğruluk analizi üzerinde etkilidir. Üretimde tek bir doğrultu üzerine tesis edilmeleri durumunda çalışma bölgesinin karakteristik özelliklerini temsil eden topografya gibi unsurların doğru tasvir edilememesi söz konusu olmaktadır ve geometrik düzeltme tam anlamıyla gerçekleştirilememektedir. Doğruluk analizinde ise kontrol noktalarının tüm bölgeye yayılım göstermediği durumlarda, analizler model genelini ifade etmek yerine kontrol noktalarıyla sınırlanmış alanı temsil etmektedir ve sonuç çıkarımlar yalnızca belirli bölge içerisinde tutarlılık göstermektedir. Doğruluk analizi için çalışma alanı sınır bölgelerine ve orta noktasına olmak üzere beş adet YKN yaygın olarak kullanılmaktadır [Mesas-Carrascosa et al., 2014].

Model doğruluğu mutlak ve bağıl doğruluk olmak üzere iki farklı şekilde hesaplanarak değerlendirilebilmektedir. Mutlak doğruluk sonuç ürünlerde meydana gelen düşey ve yatay yönlü sistematik ya da rastgele hataların istatistiki analizinde yaygın olarak kullanılmaktadır [Wijesingha, 2016]. Doğruluk kontrolü denklem 4.2'de verilen KOH formülü ile gerçekleştirilmektedir [Riazanoff and Santer, 2006].

$$KOH = \sqrt{\frac{\sum_{i=1}^n (\hat{X}_i - X_i)^2 + (\hat{Y}_i - Y_i)^2 + (\hat{Z}_i - Z_i)^2}{n}} \quad (4.2)$$

$\hat{X}_i, \hat{Y}_i, \hat{Z}_i = i$  görüntü noktasındaki hesaplanan YKN koordinatı

$X_i, Y_i, Z_i = i$  görüntü noktasındaki ölçülen YKN koordinatı

$n =$  YKN sayısı

YKN sayısı kullanıcı kontrolünde belirlenmekte ve belirli sayıdaki YKN ile model doğruluğu analiz edilebilirken birçok değişkene bağlı olan eşik değeri üzerindeki adet arttırımı beraberinde KOH değerinde tutarsızlığa yol açmaktadır.

Geleneksel fotogrametri çalışmalarında, YKN dağılımında çalışma alanı köşe konumları ve orta noktası olmak üzere beş adet YKN kullanımının yeterli olduğu

düşünülmekte ve yaygın olarak tercih edilmektedir. İHA tabanlı çalışmalarda ise bu durum farklılık göstermekte ve çok sayıda YKN kullanımı tercih edilmekte ancak optimal YKN sayısı ve dağılımı hakkında net bir ifade olmamakla birlikte bu konu üzerindeki tartışmalar devam etmektedir [James and Robson, 2014], [Manfreda et al., 2019]. Kilometrekare başına 10-20 aralığında YKN tesis edilmesinin uygun olduğunu belirtilen çalışmalar olmasına rağmen tez çalışması kapsamında elde edilen tecrübeler ve bilim dünyasında yaygın olarak kabul görmüş, YKN sayısının çalışma alanının özelliklerine bağlı olarak değişmekte olduğu, her amaç için standart bir yaklaşımının olmayacağı fikri benimsenmiştir [Gindraux et al., 2017], [Agüera-Vega, et al., 2017]. Bu doğrultuda tez kapsamında sekiz adet YKN tesis edilmiş ve fotogrametrik işlem sürecine dahil edilmiştir.

Radyometrik hatalar, yeryüzündeki nesnelere yansıyan enerjinin sensörde algılanan değeri üzerinde bozucu etkiler oluşturmaktadır. Sensör hassasiyetinin yanı sıra topografya ve zamana bağlı olarak değişen güneş açısı, atmosfer etkisi gibi unsurlar bozucu etkilerin oluşumunda ana kaynaklardır. Kamera donanımının sahip olduğu algılayıcı sensörden kaynaklanan iç hatalar, görüntü genelinde eş dağılmayan aydınlatmaya neden olarak görüntünün belirli bölgelerinde daha çok ya da daha az ışık kaydedilmesine sebep olmaktadır. Genellikle görüntü merkezi çerçeve sınırlarına göre daha parlak olmaktadır. Kaydedilen parlaklık değerindeki farklılıklar görsel yorumlamayı zorlaştırmakta ve fotoğraflar üzerindeki analizlerde yanıltıcı etkiler oluşturmaktadır. Bu noktada görüntü alımındaki kamera açısı üst düzeyde öneme sahiptir ve nadir doğrultusunda görüntü alımıyla maksimum yansıma kaydedilerek sensör yapısından kaynaklanan hata minimum seviyelere düşürülmektedir.

Atmosfer etkisi, güneş açısı ve yüzey topografyası dış etkenleri oluşturmakta ve yüzeyden yansıyan ışınım üzerinde bozucu etki oluşturarak sensörde kaydedilen değerlerin hatalı olmasına sebep olmaktadır. Atmosfer etkileri ışığın dalga boylarını farklı oranlarda saçan bulut, toz, kirlilik gibi unsurları barındırmaktadır ve bu unsurlar sensöre ulaşan ışınımı ciddi oranda etkilemektedir. Atmosfer zamana, hava koşullarına ve yüksekliğe bağlı olarak dinamik bir yapı göstermesiyle oluşturduğu etkinin modellenmesi oldukça zordur. İHA düşük irtifada görüntü alımı kabiliyeti sayesinde atmosferik etkilere nispeten daha az maruz kalmaktadır. Ancak hareket halinde görüntü alımı sebebiyle her fotoğraf çekim anında farklı güneş açısında

konumlanmaktadır ve görüntüler arasındaki aydınlanma koşulları değişkenlik göstermektedir.

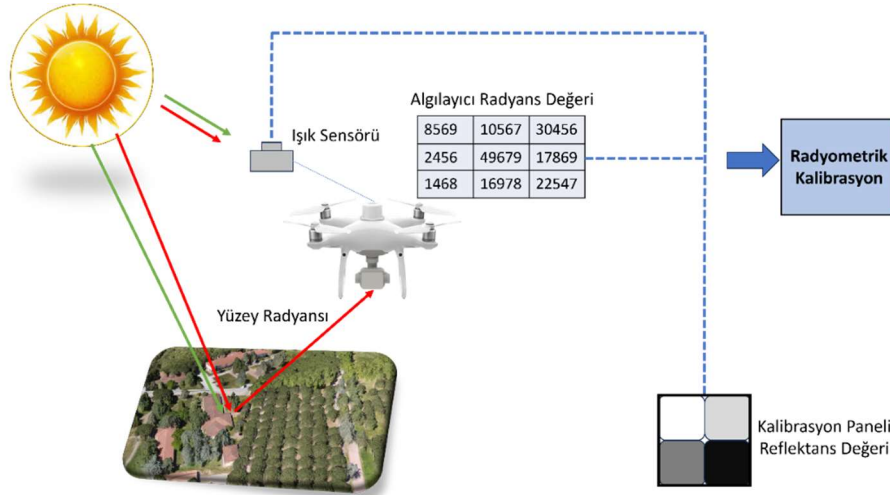
Bahsedilen bozucu etkilerin yanı sıra tez kapsamında kullanılan multispektral İHA farklı bantlarda eş zamanlı algılama yapabilme kabiliyetine sahiptir ve bu özelliği beraberinde bazı dikkat edilmesi gereken hususları meydana getirmektedir. Kamera içerisinde yer alan altı farklı sensör eş zamanlı görüntü alırken, uçuş hızı ve deklanşör hızına bağlı olarak yansıtım değerlerinin kaydedilmesinde problemler oluşabilmektedir. İHA tarafından, farklı bantlardan algılanan enerjinin eş zamanlı kaydedilebilmesi için yüksek hızlı işlemci ve hafıza kartına sahip olunması gerekmektedir. Çok bantlı görüntü analizlerinde, bindirmeli alanlarda uyuşumsuz pikseller sebebiyle renk geçişleri görülebilmekte ve analiz sonuçlarında negatif etkiler oluşturmaktadır. Bu noktada, düşük uçuş hızı ve optimal deklanşör hızı belirlenmeli ya da dur-çek gibi uçuş modları tercih edilmelidir.

Tüm bu etkilerin giderilmesi, radyometrik kalibrasyon işlemlerinin uygulanmasını gerektirmektedir. Radyometrik kalibrasyonla birlikte bu hatalar belirli ölçüde elimine edilebilmekte ve veriler sonraki analizler için daha güvenilir bir kaynak oluşturmaktadır. Özellikle değişim analizleri ve tarımsal uygulamalar gibi periyodik gözlemlerde, spektral bilginin doğruluğu önem kazanmakta ve radyometrik kalibrasyona duyulan ihtiyaç artmaktadır.

Radyometrik kalibrasyon, atmosferik etkilerin elimine edilerek piksel değerlerinden yüzey yansıtım değerlerine (reflektans) dönüşüm için öncül bir işlemdir [**Smith and Milton, 1999**], [**Dehm, 2019**]. Reflektans değeri ışık koşullarından bağımsızdır ve bu nedenle bilimsel çalışmalar için daha güvenilir bir kaynak oluşturmaktadır. İHA'nın görüntü alımında geçen süre ve değişken konumuna bağlı olarak farklılık gösteren atmosfer ve aydınlanma koşullarının spektral bilgi üzerinde oluşturduğu bozucu etkiler, kalibrasyon işleminin tekil görüntülerin her birine uygulanmasıyla ortadan kaldırılmakta ve görüntülerin bütününde standart yakalanmaktadır.

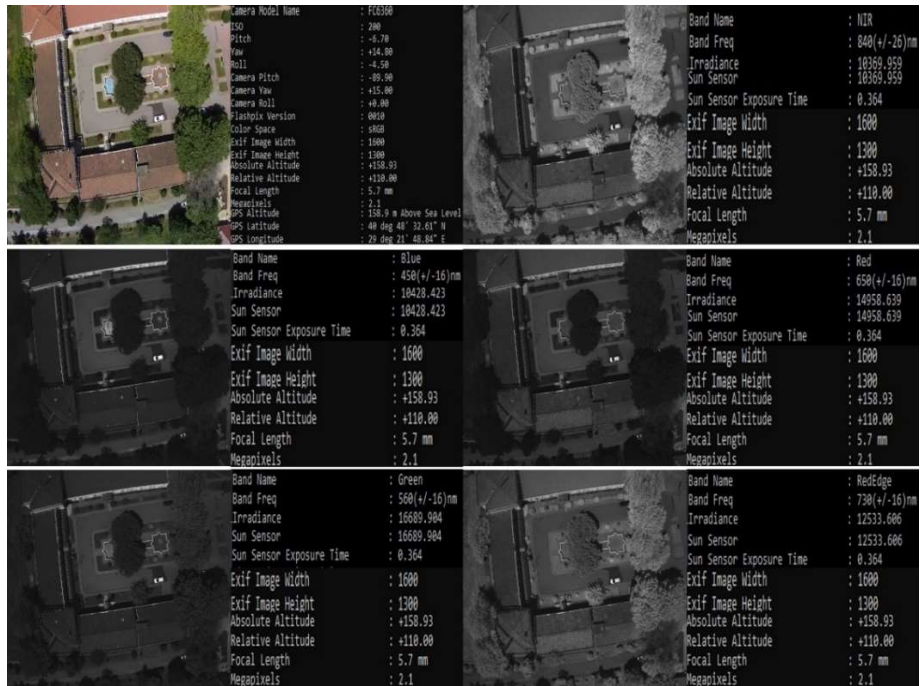
İHA üzerine monte edilmiş farklı spektral aralıklarda kayıt yapabilen algılayıcılar, radyometrik olarak kalibrasyonu tamamlanarak kullanıcılara sunulmaktadır ancak uçuş sırasında titreşim, rüzgar, sıcaklık vb. unsurların etkisiyle görüntü kaydı sırasında bozucu etkilere karşı hassastırlar [**Hakala et al., 2018**]. Bu etkileri ortadan kaldırmak için nokta bulutu üretimi öncesinde Agisoft Metahsape Pro yazılımında radyometrik

kalibrasyon işlemi gerçekleştirilmiştir ve kalibrasyon sürecine ait özet bilgiler Şekil 4.6'da verilmiştir.



Şekil 4.6: Radyometrik kalibrasyon uygulama adımları.

Kalibrasyon işlemi için öncelikli olarak görüntünün radyans değerlerine ihtiyaç duyulmaktadır. İHA üzerinde konumlanmış MS algılayıcılar, her görüntü çekim noktasında mevcut bantlar için metaveri dosyasına sahip tekil görüntüler kaydetmektedir Şekil 4.7.



Şekil 4.7: Kompozit (RGB) ve beş mono banta ait görüntülerin metaveri dosyası.

İHA, metaverilerde yer alan sensör değerlerini denklem 4.3'te belirtildiği gibi kullanarak, algılayıcının kaydettiği piksel değerlerinden radyans (L) değerine dönüşümünü otomatik gerçekleştirmektedir.


$$L(\lambda) = V(x, y) \times \frac{a_1}{g} \times \frac{DN(\lambda) - DN_{BL}}{t_e + a_2 y - a_3 t_e y} \quad (4.3)$$

Denklem 4.3'teki her pikselin koordinatlarına (x,y) bağlı olarak radyans değeri hesabında; vinyet düzeltmesi (vignetting correction, V(x,y) (denklem 4.4)), sensör kazancı (sensor gain, g), piksel değeri (digital number, DN), pozlama süresi (exposure time,  $t_e$ ) ve algılayıcı sistemin üreticisi tarafından sunulan  $a_1$ ,  $a_2$ ,  $a_3$  katsayıları kullanılmaktadır [Jiang et al.,2022], [Mamaghani et al., 2019].

$$V(x, y) = \frac{1}{1 + k_0 \times r(x,y) + k_1 \times r(x,y)^2 + k_2 \times r(x,y)^3 + k_3 \times r(x,y)^4 + k_4 \times r(x,y)^5 + k_5 \times r(x,y)^6} \quad (4.4)$$

$V(x, y)$  ifadesinde x ve y değerleri piksel koordinat sisteminde satır ve sütun değerlerini ifade etmektedir, bu değer görüntü merkezine bağlı uzaklık (r) ve polinom katsayıları ( $k_i$ ) kullanılarak hesaplanmaktadır.

İHA ile alınan fotoğraflardan reflektans değerlerine geçiş için görüntü piksellerinin parlaklık değerleri, bilinen yansıma değerleri ile eşleştirilmelidir. Bu noktada **Şekil 4.8** de örnekleri gösterilen çeşitli yansıtım panelleri yer referansı olarak kullanılmaktadır.



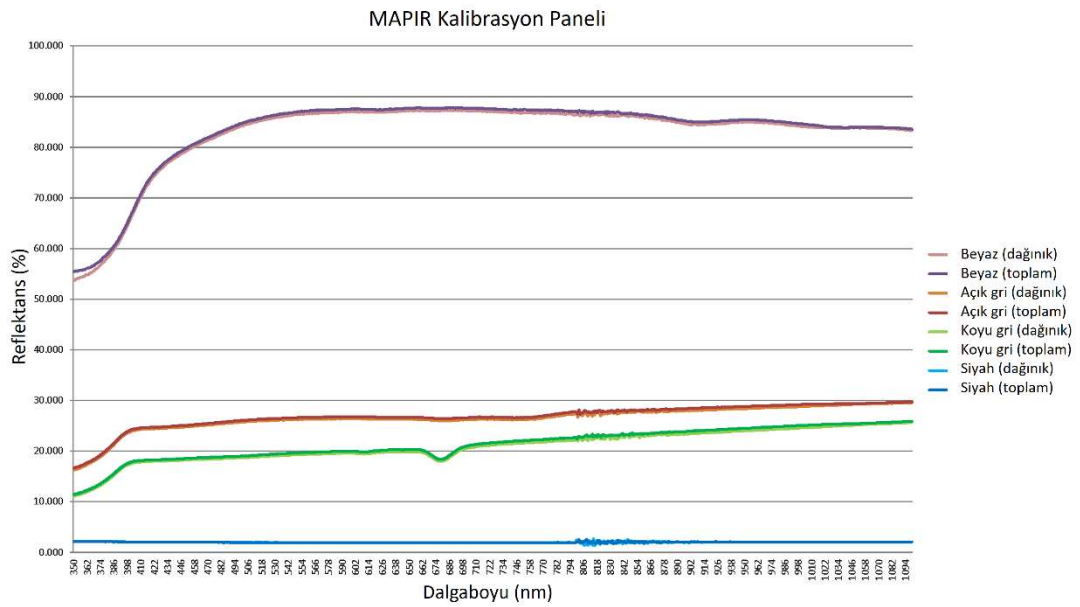
**Şekil 4.8:** Kalibrasyon paneli örnekleri: (a) Micasense RP06, (b) MAPIR V2, (c) üç farklı renk aralığındaki manuel üretilen paneller.

Bu panellere ait yansıtım değerleri spektrometre cihazları aracılığıyla ölçülmekte ve üretici firmalar tarafından kullanıcılara sunulmaktadır. Reflektans paneli ile gerçekleştirilen kalibrasyon işleminde geliştiriciler tarafından önerilen iş akış süreci uygulanmıştır [Agisoft, 2022]. Literatürde sıkça yer alan ve çalışmalarımızda karşılaştığımız önemli bir problem de Agisoft gibi paket yazılımların kullanıcılara sağladıkları çeşitli fotogrametrik ürünlerin, üretiminde faydalanılan algoritmalar hakkında bilgi sunmamalarıdır [Daniels, 2023]. Ancak Wang çalışmasında görüntü işlemede kullanılan Pix4d gibi birçok yazılımın, radyometrik kalibrasyon için denklem 4.5'i kullandığından bahsetmiştir [Wang, 2021].

$$p(\lambda) = \frac{p_{CRP}}{L_{CRP(\lambda)}} \times L(\lambda) \quad (4.5)$$

Denklem 4.5 de  $p(\lambda)$ , yüzey reflektans değerini,  $p_{CRP}$  panel reflektans değerini,  $L_{CRP(\lambda)}$  panel radyans değerini ve  $L(\lambda)$  piksel radyans değerini ifade etmektedir. Piksel radyans değeri daha öncesinde denklem 4.3'te elde edilmiştir. Panel radyans değeri ise tercih edilen panelin üretim malzemesine, görüntü alım mesafesine ve hava koşullarına göre farklılık göstermektedir. Tez çalışmasında MAPIR V2 yansıtım panelinin DJI Phantom Pro 4 İHA ile göğüs hizasından alınan görüntüleri kullanılmıştır. Panele ait radyans değerleri bu görüntülerden temin edilirken, panel reflektans değeri ise üretici

firma tarafından tedarik edilmektedir. **Şekil 4.9'**da MAPIR kalibrasyon panelinin üretici firma tarafından laboratuvar ortamında gerçekleştirdiği ölçümler neticesinde kullanıcıya sunduğu yansıtım değerleri görülmektedir. Panel üzerinde yer alan beyaz, açık gri, siyah, koyu gri olmak üzere dört farklı renk ve yansıtımdaki maddelere ait değerler ayrı ayrı sunulmuş ve farklı görüntüleme açılarından (dağınık) bile aynı yansıtım değerlerinin alınabileceği belirtilmiştir ancak dik bakış (nadir) tavsiye edilmiştir. Radyometrik düzeltme işlemine ait tüm işlem adımları Agisoft Metashape Pro yazılımında gerçekleştirilmiştir.



**Şekil 4.9:** MAPIR V2 panele ait reflektans değerleri.

### 4.1.3. 3B Fotogrametrik Ürünlerin Üretimi

Radyometrik ve geometrik kalibrasyonu gerçekleştirilmiş görüntülerin ardından nokta bulutu üretimi gerçekleştirilmektedir **Şekil 4.11.b**. Nokta bulutu, bir nesnenin 3B nokta kümeleri ile temsil edilme biçimidir ve temin edildiği kaynağa bağlı olarak renk, konum ve yoğunluk gibi bilgileri içerebilmektedir. Nokta bulutu, İHA ile alınan fotoğraflardaki ortak alana sahip görüntü çiftlerinden, stereo bakış geometrisi ile üretilmektedir [Lucieer et al., 2014]. Georeferanslandırılmış ve kalibrasyonları tamamlanmış görüntülerle üretilen nokta bulutu verisinde, tanımlı koordinat sisteminde her bir nokta için hassas konum bilgisi mevcuttur. Çalışma alanı içerisindeki yapı yükseklikleri ve yönelimleri, aydınlanma koşulları, bitki örtüsü, su

kütleleri, uçuş planı, kamera bakış açısı ve YÖA gibi birçok unsura bağlı olarak nokta bulutu yoğunluğu değişkenlik göstermektedir. Düşük kontrast, yoğun bitki örtüsü ve hareketli nesnelerin varlığı gibi etkenler, görüntü çiftlerindeki anahtar noktalar arasında düşük korelasyona sebebiyet vermekte ve nokta bulutu yoğunluğunu düşürmekte ya da hatalı konumlandırılmış gürültülü noktaların üretimine yol açmaktadır. Yüksek doğrulukta DYM üretimi öncesinde gürültülü noktaların manuel ya da otomatik yöntemlerle elimine edilmesi gerekmektedir.

DYM, raster formatlı üretilen ve her bir pikselde o konuma ait yükseklik değeri bilgisini içeren bir görüntüdür [Frazier and Singh, 2021]. DYM, nokta bulutu kaynağından üretilmekte ve herhangi bir yapının yüzey yüksekliğini temsil etmektedir, DAM ise DYM kaynağından türetilmekte ve yalnızca zemin noktalarına ait yükseklik bilgisini içermektedir **Şekil 4.10**.

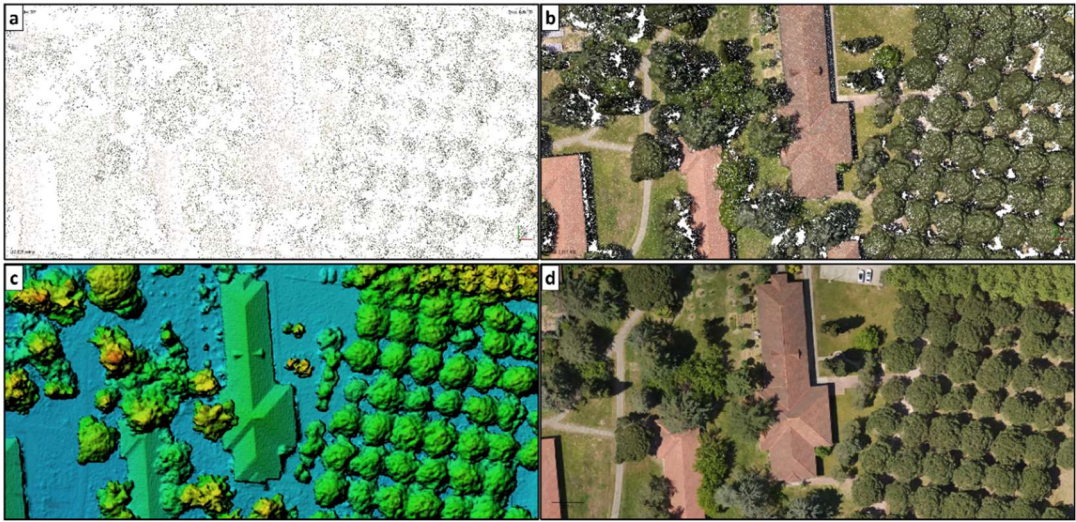


**Şekil 4.10:** DYM ve DAM kavramlarının temsili gösterimi.

**Şekil 4.10**'da görüldüğü gibi DYM bina, ağaç ve tepe alanlarının en üst kotlu noktalarını içerirken, DAM yalnızca çıplak topografyaya ait noktaları temsil etmektedir. DAM üretiminde ilk adım SFM tabanlı üretilen nokta bulutunun sınıflandırılması işlemidir. Bu işlem çeşitli sınıflandırma algoritmaları yardımıyla otomatik ya da manuel gerçekleştirilebilmektedir ve bu süreçte nokta kümeleri zemin ve zemin üstü olmak üzere iki temel sınıfa atanmaktadır.

DYM ve DAM mutlak yükseklik değerlerine ait bilgilere sahipken, bu modellerin diferansiyel farkıyla türetilen NDYM bağıl yükseklik bilgisini içermektedir. NDYM, grid formatlı DYM'den DAM verisinin çıkarılmasıyla üretilmekte ve bu işlem her bir grid için gerçekleştirildikten sonra raster formatlı görüntüye dönüşüm yapılmaktadır. NDYM, tüm tekil nesnelerin tasvirine olanak sağlamakta ve kot bilgisi yerine bu nesnelerin yüksekliğine dair bilgiler sunmaktadır.

Son işlem adımında ise fotogrametrik iş akışının nihai ürünü olan ortomozaik üretimi gerçekleştirilmektedir **Şekil 4.11.d**. Geleneksel fotogrametri ile üretilen ham ortomozaiklerde yüksek objelerin tasvirinde eğiklik gibi hatalar görülmekte ve operatörler tarafından gerçekleştirilen ek geometrik düzeltmelere ihtiyaç duyulmaktadır. İHA kaynaklı üretilen ortomozaikler ise DYM verisinin altlık olarak kullanılması ve gerçek ortofotolardan oluşması sebebiyle geometrik olarak anlamlı ve birçok çalışma konusu için altlık olarak kullanılabilen son derece önemli bir veri kaynağını oluşturmaktadır. Gerçek ortomozaikler, dik bakışlı (nadir) geometri şartını koruyarak bina, ağaç, köprü gibi yüksek yapılara ait detayların gerçeğe yakın görüntüsünü sağlamaktadır. Gerçek ortofotolar belediyeler gibi yerel yönetimlerce yürütülen çeşitli çalışmalarda, zaman ve maliyet dengesinin korunmasında son derece etkilidir.



**Şekil 4.11:** İHA verilerinden üretilen örnek ürünler: (a) seyrek nokta bulutu, (b) yoğun nokta bulutu, (c) DYM, (d) ortomozaik.

## 4.2. AÖ/AK Sınıflandırma

Teknolojinin gelişimiyle, beraberinde getirdiği avantajlar algılama sistemleri üzerinde de oldukça etkin olmuştur. Mekansal çözünürlük kavramının her geçen gün önemini arttırmasıyla birlikte, yüksek çözünürlüklü verilerin işleme süreci de önem kazanmıştır. Veri boyutu ve gereksinim duyulan donanım ihtiyacı arasındaki denge korunmaya çalışılsa da önüne geçilemez bir hal almıştır. Mevcut yazılımların kısıtlı veri işleyebilme kapasiteleri donanım gücüne bağlılığı da etkisiz kılmakta ve güçlü donanımlarla bile veri işleme olanaksız hale gelmektedir. AÖ/AK haritalarının üretiminde uzaktan algılama kaynaklarının kullanımı beraberinde güçlü bir sınıflandırma yöntemi gerekliliğini doğurmaktadır [Rodriguez-Galiano et al., 2012]. Bu haritaların en doğru şekilde üretimi için mekansal çözünürlük kavramı önem kazanmaktadır. Çözünürlük arttıkça üretim doğruluğu artmaktadır ancak büyük veri boyutu, nesnelerin tasvirinde çok sayıda pikselin yer alması ve karmaşık hale gelen sınıflandırma süreci analiz edilmeli ve en uygun yöntemlerin belirlenmesi gerekmektedir. İHA'lar ile bir piksele karşılık gelen alanın cm düzeyine kadar düşmesiyle konumsal ve spektral doğruluğu üst seviyede güçlü bir veri kaynağı oluşmuştur.

Bu verinin analizinde piksel ve obje tabanlı olmak üzere yaygın olarak kullanılan iki temel yaklaşım bulunmaktadır. Piksel tabanlı görüntü analizi, kolaylığı ve yüksek verimliliği ile uzaktan algılama görüntülerinin sınıflandırılmasında uzun yıllardır tercih edilen popüler bir yöntemdir. Bir pikselin birden fazla sınıf bilgisi içermesi ve görüntü üzerinde bir piksele karşılık gelen alandaki baskın sınıfın spektral bilgisinin ön plana çıkması nedeniyle, düşük çözünürlüklü verilerin değerlendirilmesinde piksel tabanlı sınıflandırma tercih edilmektedir [Blaschke et al., 2014], [Ozturk, 2022]. Uydu görüntülerinin sağladığı mekansal çözünürlük piksel tabanlı çalışmalarda yüksek performans göstermektedir. Algılama sistemlerindeki gelişmeler ve İHA gibi farklı veri temin araçlarının ortaya çıkışıyla, mekansal çözünürlükler hızlı bir şekilde artmış ve bir sınıf birden fazla pikselle tasvir edilebilir hale gelmiştir [Yu et al. 2006]. Ancak geleneksel piksel tabanlı sınıflandırıcılar komşuluk ilişkilerini dikkate almazken yalnızca tekil piksellerin spektral bilgilerini kullanmaktadır [Blaschke and Strobl, 2001], [Ming et al., 2015]. Yüksek çözünürlüklü bir veride, benzer spektral bilgiye sahip olan fakat farklı sınıflara ait olan pikseller sınıflandırıcı performansını düşürmekte ve yanlış sınıflandırmaya sebep olmaktadır [Hossain et al., 2019],

[Ventura et al., 2018]. İHA'nın temel kaynak olarak kullanıldığı sınıflandırma çalışmalarında doku ve spektral bilginin yorumlanmasındaki karmaşıklık, piksel tabanlı yöntemlerin tercih edilmesi durumunda sonuçlar üzerinde tuz-biber gürültüsü oluşturmaktadır [Duro et al., 2012], [Hussain et al., 2013]. Bu gibi problemlerin çözümü için yüksek çözünürlüklü verilerin sınıflandırmasında obje tabanlı yaklaşımlar önerilmiştir [Lang, 2008]. Yüksek çözünürlüklü bir görüntü milyonlarca piksel içermektedir, obje tabanlı yaklaşımlarda bu piksellerin temsil ettiği objeler belirlenmekte ve sınıflandırmada tekil piksellerin özellikleriyle sınırlı kalmayıp bu objeleri oluşturan piksel gruplarının spektral, mekansal ve dokusal bilgilerine dayalı birçok veri elde edilebilmektedir. Bu şekilde objelere dair çıkarımı gerçekleştirilebilen her bir özellik sınıflandırıcılara girdi veri olarak sunulabilmektedir [Tonbul, 2021], [Jensen, 2005].

#### **4.2.1. Piksel Tabanlı Görüntü Sınıflandırma**

Pikseller dijital görüntünün en küçük elemanları olarak ifade edilmektedir [Fisher, 1997]. Geleneksel piksel tabanlı görüntü sınıflandırma yöntemleri, her pikselin yalnızca bir AÖ/AK sınıfına ait bilgileri içerdiğini varsaymaktadır. Bu yöntemde her bir piksel sınıflandırma işlemine tabi tutulur ve spektral bilgileriyle bunlardan türetilen (temel bileşenler, indeksler vb.) veriler girdi değerleri olarak kullanılır [Li et al., 2014], [Tonbul, 2021], [Ozturk, 2022]. Piksel tabanlı sınıflandırıcılar kontrollü ve kontrolsüz olmak üzere ikiye ayrılmaktadır. Kontrolsüz sınıflandırma işleminde, herhangi bir örnek veri olmaksızın piksel değerlerine bağlı olarak kümeleme işlemi gerçekleştirilir ve belirlenen sınıflarla ilişkilendirilirler [Lillesand et al., 2015], [Ali, 2015]. Çalışma bölgesinde yer alan çeşitliliğe bağlı olarak, küme adeti ve kullanılacak bant bilgileri önceden belirlenir ve spektral bilgiye bağlı olarak kümeleme işlemi tamamlanır. Kümeler yalnızca spektral bilgilerle ilişkilendirilmiş durumdadır ve kümelere ait AÖ/AK sınıfları kullanıcı tarafından belirlenmektedir [Çölkesen, 2015]. Çok sayıda kontrolsüz sınıflandırıcı mevcuttur, K-ortalama ve onun varyantı ISODATA, SOM (Self Organizing Map) yaygın olarak kullanılmaktadır [Dhodhi et al., 1999]. Kontrollü sınıflandırmada ise sınıflar belirlidir ve bu sınıflara ait örnek piksellerden oluşan alanlara dayalı olarak model kurulmaktadır. Piksellere ait istatistiksel değerler hesaplanır ve kurulan model tüm görüntü üzerinde uygulanarak hesaplanan olasılık değerlerine göre sınıflandırma işlemi gerçekleştirilir. Kontrollü sınıflandırma

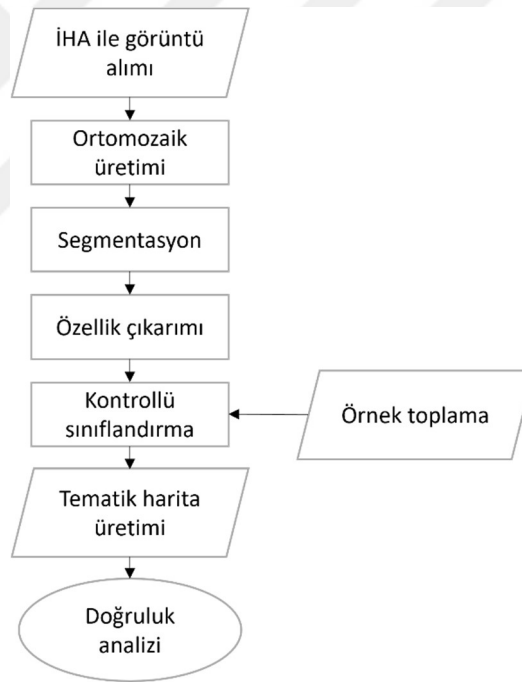
temelinde geliştirilen en büyük benzerlik (Maksimum Likelihood) [Settle and Briggs, 1987], K- en yakın komşuluk [Zhu and Basir, 2005], en kısa mesafe (minimum distance) [Atkinson and Lewis, 2000] gibi birçok sınıflandırıcı bulunmaktadır. Sonraki yıllarda ise MÖ teknikleri sınıflandırma sürecinde sıkça tercih edilir hale gelmiş ve RF, SVM gibi çeşitli yöntemler alternatif olarak ortaya koyulmuştur [Kavzoglu and Mather, 2003], [Gislason et al., 2006], [Gualtieri and Crompt, 1999], [Huang et al., 2002].

Çözünürlük, piksel tabanlı üretilen harita doğruluğunu ve sınıflandırıcının performansını etkileyen temel faktördür. Düşük ve orta çözünürlüklü görüntülerde nesnelere yansıyan elektromanyetik enerji birden fazla sınıfa karşılık gelen pikselleri oluşturmaktadır [Ozturk, 2022]. Çözünürlük kalitesindeki artış ile de yeryüzündeki nesnelere görüntü üzerinde tasvir eden piksel sayısı artmakta ve nesnenin içerdiği spektral bilgi çeşitlilik göstermektedir [Hayes et al., 2014]. Bu ve benzeri problemlerin çözümünde obje tabanlı görüntü analizleri ön plana çıkmaktadır.

#### 4.2.2. Obje Tabanlı Görüntü sınıflandırma (OTGS)

Son 10 yılda algılayıcı teknolojilerindeki gelişimle birlikte ulaşılan yüksek mekansal çözünürlük, uzaktan algılama verileriyle AÖ/AK sınıflandırma çalışmalarında obje tabanlı yöntemleri ana kaynak haline getirmiştir [Zhang et al., 2017]. Obje tabanlı görüntü analizleri (OTGA) yüksek çözünürlüklü İHA [Shukla and Jain, 2020], Worldview-3 [Sertel et al., 2022], Pleiades [Lelong and Herimandimby, 2022] gibi veri kaynaklarının kullanıldığı birçok çalışmada yer alırken, IKONOS, QuickBird gibi düşük ya da orta çözünürlüklü kaynaklarda kullanımı oldukça azdır [Blaschke, 2010], [Mollick et al., 2023]. Obje tabanlı yaklaşımlar, piksel tabanlı yaklaşımların dezavantajlarını iyileştirmek için geliştirilmiştir [Blaschke et al., 2014]. Uzaktan algılama yöntemleri ile temin edilmiş görüntülerden anlamlı nesnelere oluşumu için piksellerin doku, şekil, komşuluk ilişkilerine dayalı özellik çıkarımı ile çalışmaktadırlar [Willhauck et al., 2000]. OTGA genel iş akışı Şekil 4.12'de gösterilmiştir. Öncelikli işlem, görüntü üzerinde bulunan benzer özelliklere sahip piksellerin, homojen yapıları farklı karakterlerde nesnelere oluşturmasıdır ve bu işlem segmentasyon olarak adlandırılmaktadır. Piksellerin sahip olduğu değerler, görüntü ölçeği ve nesnelere biçimini içeren çeşitli parametreler segmentasyon sürecini kontrol etmekte ve segmentlerin oluşumunda doğrudan etkili olmaktadır [Forghani et al.,

2007]. Segmentler farklı özelliklerin ve sınıfların tasvirinde genellikle piksellerin tekil değerlendirilmesine kıyasla daha anlamlıdır, bunun temel nedeni herhangi bir sınıfın tanımlanmasında spektral bilgiden fazlasını içerme potansiyelleridir [Pal and Mather, 2003]. Spektral bilginin piksel bazlı kullanımının yanı sıra komşuluk ilişkilerinin, doku, geometri ve mekansal bilgi gibi değişkenlerin de dahil olduğu segmentasyon süreci, kullanıcının analizlerde daha esnek olmasını ve segmentlere dayalı çeşitli özelliklerin çıkarımını kolaylaştırmaktadır [Jensen, 2005], [Tonbul, 2021]. Segmentasyon işleminin ardından, çalışma alanı için belirlenmiş sınıflar ve bu sınıfların ayırımında etken olan özelliklerin çıkarımı için örnek segmentler toplanmaktadır. Örnek veriler ile kurulan model eğitilmekte ve tüm görüntü üzerinde çalıştırılmaktadır. OTGA'da milyonlarca piksel yerine segmentlerin sınıflandırılması işlemi gerçekleşmektedir ve böylelikle işlem süreci büyük oranda azalmaktadır.



Şekil 4.12: Obje tabanlı görüntü analizi iş akışı.

Yüksek çözünürlüklü veride piksel boyutu, ilgilenilen nesnenin ortalama boyutundan çok daha küçüktür. Segmentasyon, yüksek düzeyde ayrıntıyı birleştirmenin ve analiz için kullanılabilir objeleri üretmenin etkili bir yoludur [Lang, 2008]. Görüntünün sahip olduğu ayrıntı düzeyi ve karmaşıklık azaltılarak, görüntü içeriğinin kavranabilir hale getirilmesidir [Baatz et al., 2008], [Shapiro and Stockman, 2001]. İHA ile üretilen ortomozaik üzerindeki ortak özelliklere sahip piksellerin belirli heterojenlik

eşik değeri içerisinde gruplanarak oluşturduğu alanlar segmentleri ifade etmektedir [Ma et al., 2018]. Objeye tabanlı görüntü sınıflandırma işleminde segmentasyon, sınıflandırma işlemine girdi verisi olarak sunulacak segmentlerin üretiminde rol aldığından, segmentasyon kalitesi AÖ/AK sınıflandırma işleminin sonucunu doğrudan etkileyen, son derece önemli bir işlem adımıdır [Gao et al., 2011], [Kavzoglu and Tonbul 2017], [Hossain et al., 2019], [Castilla and Hay, 2008]. Literatürde çoklu çözünürlük (multiresolution), satranç tahtası (chessboard), dörtlü ağaç (quad-tree), kontrast bölümlenmesi (contrast split) gibi çeşitli segmentasyon yöntemleri mevcuttur [Dey et al., 2010], [Çölkesen, 2015]. Segmentasyon işleminin uygulanmasında yukarıdan aşağı (top-down) ve aşağıdan yukarı (bottom-up) olarak bilinen iki temel yöntem bulunmaktadır [Definiens, 2006]. Satranç tahtası, dörtlü ağaç, kontrast bölümlenme yukarıdan aşağı yöntemi esasında çalışmaktadır ve bu yöntem büyük görüntü parçalarını bölerek daha küçük boyutlu parçaların oluşmasını sağlamaktadır. Bu çalışmada yüksek çözünürlüklü verilerle gerçekleştirilen, objeye tabanlı sınıflandırmada son derece efektif sonuçlar üreten ve aşağıdan yukarı yöntemini esas alarak çalışan çoklu çözünürlük segmentasyon yöntemi kullanılmıştır. eCognition Developer V9 yazılımı açıklanan segmentasyon yöntemini arayüzüne entegre ederek kullanıcılara sunmaktadır ve tez çalışması kapsamında uygulama bölümünde bu programdan faydalanılmıştır. Çoklu-çözünürlük segmentasyon yöntemi uzaktan algılanmış görüntülerde AÖ/AK tespiti çalışmalarında bölütleme işleminde sıkça tercih edilmektedir [Witharana and Civco, 2014], [Kavzoglu et al., 2017], [Comert and Kaplan, 2018]. Bu yöntem her piksel ile bir görüntü objesi ya da bölge oluşturarak çalışmaktadır ve bu objelerin komşuluk ilişkilerini inceleyerek kendi içerisinde belirlediği homojenlik eşik değerine ulaşana kadar objeleri birleştirmektedir [Baatz and Schäpe, 2000], [Chen et al., 2009], [Maxwell, 2005]. Çoklu çözünürlük bölütleme yöntemi için homojenlik sınır değerini belirleyen ölçek parametresi, biçim ve bütünlük olmak üzere üç ana bileşenin tanımlanması gerekmektedir. Bu parametrelerin optimum seçimi segmentasyon kalitesi ve homojen objelerin oluşumunda son derecede etkili olmaktadır. Ölçek parametresinin çok yüksek değerlerde seçilmesi objelerin daha büyük boyutlu oluşmasına ve bir segmentin birden fazla sınıfa karşılık gelen veriyi içermesine sebep olmaktadır. Çok düşük değerlerde seçilmesi durumunda ise aşırı bölütleme ortaya çıkmakta ve sınıflandırıcı performansı olumsuz yönde etkilenmektedir.

Ölçek parametresi birimsiz bir parametredir ve ilk obje ile birleştirilmeye aday objeler arasındaki renk ve şekil homojenliğinin maksimum farkını tanımlamaktadır [Eisank et al., 2014]. Renk homojenliği spektral değerleri esas almaktadır. Şekil homojenliği segmentin iki boyutlu şeklinin ideal formdan sapmasını ölçmektedir, bütünlük ve yumuşaklık kavramlarından oluşmaktadır. Bütünlük, bir daire kullanarak bir nesnenin kümelenmiş piksellerinin yakınlığını belirler. Yumuşaklık ise bir objenin kareye olan benzerlik düzeyini tanımlamaktadır. Heterojenlik değeri, renk ve şekil değişkenlerinin ağırlıklarının tanımlanması ile belirlenmektedir [Çölkesen, 2015]. Segmentlerin üretiminde yer alan tüm değişkenlere karşılık gelen eşitliklerin matematiksel ifadeleri denklem 4.6-4.10 ile ifade edilmiştir.  $\Delta h_{renk}$ ,  $\Delta h_{şekil}$ ,  $\Delta h_{bütünlük}$ ,  $\Delta h_{yumuşaklık}$  sırasıyla spektral heterojenlik, şekil, bütünlük, yumuşaklık kriterlerini ifade etmektedir. Denklem 4.6-4.7’de N spektral bant sayısını, W kullanıcı tarafından tanımlanan bant ağırlığını, n objelere ait piksel sayısını,  $\sigma_k$  piksellere ait standart sapmaların toplamını ifade etmektedir [Tian and Chen, 2007].

$$\Delta h_{renk} = \sum_{i=1}^N W_i \times \sigma_k \quad (4.6)$$

$$\sigma_k = \left( n_{birleşim} \sigma_i^{birleşim} - \left( n_{obj1} \sigma_i^{obj1} + n_{obj2} \sigma_i^{obj2} \right) \right) \quad (4.7)$$

Şekil kriterinde bütünlük ve yumuşaklık değişkenleri rol almaktadır (Eşitlik 3). Bütünlük ( $\Delta h_{bütünlük}$ ) ile ağırlığın ( $W_{bütünlük}$ ) çarpımı ve yumuşaklık ( $\Delta h_{yumuşaklık}$ ) ile ağırlığının ( $1 - W_{bütünlük}$ ) çarpımının toplamı şeklinde hesaplanmaktadır. Kullanıcı tanımlı bütünlük ağırlığı 0 – 1 aralığında değerler almaktadır. Bütünlük ve yumuşaklık değerlerinin her ikisi de şeklin heterojenliğini ya da homojenliğini temsil etmektedir. Bütünlük değerinin yüksek ağırlıklandırılması spektral kontrasta olan bağlılığı azaltır ve farklı şekillere sahip nesnelere ayrımını sağlar [Castillo, 2020]. Bütünlük ( $\Delta h_{bütünlük}$ ) heterojenliği objenin kenar uzunluğu ( $l$ ) ve toplam piksel sayısının karekökü yardımıyla, yumuşaklık heterojenliği ise objenin kenar uzunluğu ve sınırlayıcı kutunun kenar uzunluğu ( $b$ ) bağıntılarıyla hesaplanmaktadır (denklem 4.8-4.10).

$$\Delta h_{şekil} = W_{bütünlük} \Delta h_{bütünlük} + (1 - W_{bütünlük}) \Delta h_{yumuşaklık} \quad (4.8)$$

$$\Delta h_{bütünlük} = n_{birleşim} \frac{l_{birleşim}}{\sqrt{n_{birleşim}}} - \left( n_{obj1} \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} \frac{l_{obj2}}{\sqrt{n_{obj2}}} \right) \quad (4.9)$$

$$\Delta h_{yumuşaklık} = n_{birleşim} \frac{l_{birleşim}}{b_{birleşim}} - \left( n_{obj1} \frac{l_{obj1}}{b_{obj1}} + n_{obj2} \frac{l_{obj2}}{b_{obj2}} \right) \quad (4.10)$$

Renk ve şekil kriterine bağlı homojen piksellerden üretilen segmentlerin oluşumunun genel ifadesi ( $I_{segment}$ ) denklem 4.11'de yer almaktadır. Kullanıcı tanımlı şekil ağırlığı ( $W_{şekil}$ ) 0-1 aralığında değer almaktadır ve görüntü üzerinde spektral değerlere ya da şekle göre ağırlıklandırma yapılabilmektedir. Segment üretiminde objelerin spektral ayrımı ön planda tutulmak isteniyorsa renk ağırlığı, mekansal özellikler ön plana çıkarılmak isteniyorsa şekil ağırlığı arttırılmaktadır.


$$I_{segment} = (1 - W_{şekil})\Delta h_{renk} + W_{şekil}\Delta h_{şekil} \quad (4.11)$$

Bu parametrelere ait değerlerin seçimine dair birçok çalışma incelenmiştir ve genelinin istatistiki yöntemlerle birlikte görsel analizleri de dikkate aldığı görülmüştür. Çeşitli kombinasyonların sonuçlarının deneme yanılma aracılığıyla analiz edildiği çalışmalar mevcut olmakla birlikte, tez çalışması kapsamında optimum parametre arayışına karşılık, çoklu-çözünürlük bölütleme yöntemi için geliştirilmiş ölçek parametresi belirleme (Estimation of Scale Parameter -ESP2) aracından faydalanılmıştır [**Drăgut et al., 2010**]. ESP-2 aracı ölçek değerindeki tanımlı artış aralığına bağlı varyasyonları hesaplamakta ve lokal varyans (LV) değerini baz alarak grafikler oluşturmaktadır [**Tonbul, 2021**], [**Kalkan, 2011**]. Bu grafikler ideal ölçek parametresinin belirlenmesi için analiz edilmektedir. Optimum ölçek parametresi LV'nin pik yaptığı noktalardaki değerler dikkate alınarak seçilmektedir [**Colkesen et al., 2023**], [**Drăgut et al., 2010**], [**Kavzoglu et al., 2018**]. LV, çoklu çözünürlük algoritmasıyla oluşturulan her bir objenin belirlenen ölçek değerlerine göre ortalama standart sapmasını hesaplamaktadır [**Ozturk, 2022**]. ESP-2 iteratif şekilde çalışmakta ve mevcut LV değerinin bir önceki değere eşit ya da daha düşük bulunması durumunda sonlanmaktadır. Denklem 4.12 ölçek değerindeki değişime bağlı olarak hesaplanan lokal varyansın değişim oranının (RoC) grafiğini oluşturan; objenin lokal varyansı ( $LV_L$ ) ve bir sonraki seviyedeki objenin lokal varyansı ( $LV_{(L-1)}$ ) değerlerini içeren ifadeyi göstermektedir.

$$RoC = \left( \frac{LV_{(L)} - LV_{(L-1)}}{LV_L} \right) \times 100 \quad (4.12)$$

**Şekil 4.13**'te çalışma sahasına ait ortomozaik üzerindeki örnek alanda, ölçek parametresinin farklı değerlerde seçimine bağlı olarak, segmentlerin boyut ve

içerdikleri sınıf bilgisindeki değişime ait örnekler gösterilmiştir. Şekil ve bütünlük kriterleri sabit tutularak ölçeğin artırılmasıyla oluşan değişimler incelendiğinde, düşük ölçek parametresi değerinin (20) tercih edildiği durumlarda üretilen segmentlerin küçük boyutlu ve çok sayıda olduğu görülmektedir. Bu durumda bina, ağaç, yol gibi nesnelere çok sayıda görüntü objesiyle tasvir edilmektedir ve buna bağlı olarak yorumlanacak ve sınıf ataması gerçekleştirilecek segment sayısı artmaktadır. Karşılaşılan bu örnek, yüksek performans ve doğru yorumlama için güçlü bir modelle birlikte donanım ihtiyacı doğurmaktadır. Ölçek parametresi değerinin yüksek seçildiği örneklerde ise segment boyutları oldukça büyük ve nesnelere tasvirinde daha az sayılı segmentle başarılı sonuçlar ortaya çıktığı görülmektedir. Spektral ve biçimsel olarak benzer özellikteki yol ağlarının, bina çatı yüzeylerinin ve yeşil alanların çok daha az sayıda segment ile kapsanabilmektedir ancak benzer spektral değerlere sahip beton yapıları çatı yüzeyleri ya da duvarların yol ağları ile birleşimi hususunda dikkatli olunmalıdır.



**Şekil 4.13:** Farklı ölçek parametresi değerlerinde segmentasyon sonuçları.

Görüntü üzerindeki objelerden anlamlı bilgilerin çıkarımı ve objelerin ayrımı gibi gereksinimler amacıyla çeşitli görüntü özellikleri tanımlanmaktadır. Spektral, doku, geometri bilgileri, görüntü objelerinin yorumlanmasında temel özellikleri oluşturmaktadır. Spektral özellikler çeşitli bantlardaki piksellere dair elektromanyetik enerji bilgisini değerlendirirken, doku özellikleri tek bir bant içerisindeki spektral özelliklerin dağılımından türetilmektedir. Geometrik bilgiler ise bir görüntü objesinin kapladığı alan, kenar uzunluğu, kare şekliyle uyumu gibi obje içerisinde yer alan

piksellerin bütününün dahil olduğu özelliklerdir. Segmentasyon sürecinin ardından her bir görüntü objesinin ayrımı amacıyla segmentler sahip oldukları bu özellikler ile yorumlanmaktadır. Bunlara ek olarak obje tabanlı görüntü analizinde, objelerin tekil değerlendirilmelerinin yanı sıra komşuluk ilişkilerine bağlı çıkarımlar da yapılabilmektedir.

### 4.2.3. Özellik Çıkarımı

Spektral özellikler ve bunlara dayalı üretilen indeksler, vejetasyon alanlarının görüntülenmesi ve haritalandırılması, bitki sağlığı analizi, toprak ve su yapılarının bileşenlerinin değerlendirilmesi gibi birçok alanda yaygın olarak kullanılmaktadır [Bannari et al., 1995], [Kowalska et al., 2018], [Hunt Jr et al., 1989]. Görüntünün farklı bantlarında sahip olunan verilerle üretilen indeks değerleri, objelerin ayrımında fayda sağlayan ek bilgiler oluşturmaktadır. Tez çalışması kapsamında üretilen 5-bantlı ortomozaik ve bu veriden temin edilen spektral özellikler **Tablo 4.1**'de yer alırken bunlardan türetilen indisler de **Tablo 4.2**'de gösterilmiştir.

**Tablo 4.1:** Bant değerlerinden türetilen spektral bilgiler.

Özellik	Açıklama
K	Kırmızı Bant piksel değerleri ortalaması
Y	Yeşil Bant piksel değerleri ortalaması
M	Mavi Bant piksel değerleri ortalaması
KK	Kırmızı Kenar Bant piksel değerleri ortalaması
YKÖ	Yakın Kızılötesi Bant piksel değerleri ortalaması
SS. K	Kırmızı Bant standart sapma değeri
SS. Y	Yeşil Bant standart sapma
SS. M	Mavi Bant standart sapma
SS. KK	Kırmızı kenar Bant standart sapma
SS. YKÖ	Yakın kızılötesi Bant standart sapma
Parlaklık	Bant değerlerinin ortalaması
Maksimum fark	Bantlar arası maksimum fark

**Tablo 4.2:** Bant oranlarından türetilen indisler.

İndis	Formül	Referans
BRI	$M / M+Y+K$	[Kawashima and Nakatani, 1998]
GLI	$(2 \times Y-M-K) / (2 \times Y+M+K)$	[Louhaichi et al., 2001]
GRI	$(Y/(M+Y+K)) \times 100$	[Kawashima and Nakatani, 1998]
RGBVI	$(Y^2-M \times K) / (Y^2-M \times K)$	[Bendig et al., 2015]
RI	$K^2 / M \times Y^3$	[Wu et al., 2009]
RRI	$(K/M+Y+K) \times 100$	[Kawashima and Nakatani, 1998]
NDRGI	$(K-Y) / (K+Y)$	[Yang et al., 2008]
TGI	$Y-(0.39K-0.69M)$	[Woebbecke et al., 1995]
ER	$(1.4 \times K) - Y$	[Mao et al., 2003]
ARI1	$(1/Y) - (1/KK)$	[Gitelson et al., 2001]
ARI2	$YK\ddot{O} \times (1/Y) - (1/KK)$	[Gitelson et al., 2001]
CIVE	$0.44 \times K - 0.88 \times Y + 0.39 \times M + 18.79$	[Kataoka et al., 2003]
CIWI	$NDVI + KK$	[Mo et al., 2007]
NDVI	$(YK\ddot{O} - K) / (YK\ddot{O} + K)$	[Rouse et al., 1974]
DVI	$YK\ddot{O} - KK$	[Merzlyak et al., 1999]
VEG	$Y / ((K^{0.67}) \times (M^{0.33}))$	[Hague et al., 2006]
TVI	$60 \times (YK\ddot{O}-Y) / 100 \times (YK\ddot{O}+Y)$	[Broge and Leblanc, 2004]
SR	$YK\ddot{O} / KK$	[Peñuelas, 1997]
SIPI	$(YK\ddot{O} - M) / (YK\ddot{O} + M)$	[Guo et al., 2022]
SAVI	$(1.5 \times (YK\ddot{O}-K)) / (YK\ddot{O} + K + 0.5)$	[Huete, 2002]
RVI	$YK\ddot{O} / K$	[Jordan, 1969]
RGR	$K / Y$	[Gamon and Surfus, 1999]
ExG	$(2 \times Y) - (M) - (K)$	[Woebbecke et al., 1995]
NDWI	$(Y- YK\ddot{O}) / (Y + YK\ddot{O})$	[Li et al., 2020]
NDRE	$(YK\ddot{O} - KK) / (YK\ddot{O} + KK)$	[Gitelson and Merzlyak, 1997]
MVI	$\sqrt{(YK\ddot{O} - K)/(YK\ddot{O} + K) + 0.5}$	[Rouse et al., 1974]
MSR	$(YK\ddot{O} / K + 1) / \sqrt{YK\ddot{O}/K + 1}$	[Chen, 1996]
MRESR	$YK\ddot{O} - M / KK - M$	[Sims and Gamon, 2002]
MCARI	$(KK \times [(KK - K) - 0.2(KK-Y)]) / K$	[Daughtry et al., 2000]

**Tablo 4.2 (devamı):** Bant oranlarından türetilen indisler.

İndis	Formül	Referans
PSRI	$(K - M) / KK$	[Merzlyak et al., 1999]
NLI	$YKÖ^2 - K / YKÖ^2 + K$	[Goel and Qin, 1994]
LAI	$\frac{3.618 \times 2.5 \times ([YKÖ] - [K])}{[YKÖ] + 6 \times [K] - 7.5 \times [M] + 1} - 0.118$	[Boegh et al., 2002]
MSAVI2	$\frac{2 \times YKÖ + 1 - \sqrt{(2 \times YKÖ)^2 - 8(YKÖ - K)}}{2}$	[Qi et al., 1994]
GRVI	$Y - K / Y + K$	[Tucker, 1979]
VI <sub>opt</sub>	$1.45 \times (YKÖ^2 + 1) / (KK + 0.45)$	[Ma, 2017]
EVI	$(YKÖ - K) / (YKÖ + 6 \times K - 7.5 \times M + 1)$	[Gao et al., 2000]
GOSAVI	$1.16 \times (YKÖ - Y) / (YKÖ + Y + 0.16)$	[Rondeaux et al., 1996]
ExGR	$2 \times Y - K - M - 1.4 \times K - Y$	[Meyer and Neto, 2008]
IPVI	$YKÖ / (YKÖ + K)$	[Payero et al., 2004]
MRENDVI	$\frac{YKÖ + KK}{YKÖ + KK - 2 \times M}$	[Sims and Gamon, 2002]


Geometrik özellikler bir görüntü objesinin içerisinde yer alan piksellere dayalı hesaplamalar ile gerçekleştirilmektedir. Objelerin düzenli şekillere benzerlik oranları, kapsadıkları piksel sayısı, komşu objelere olan sınır hattı uzunluğu gibi temel özellikler obje tabanlı sınıflandırma için segmentlerin ayırt edilebilirliğinde etken olan unsurlardır **Tablo 4.3**.

**Tablo 4.3:** Geometrik özellikler.

Özellik	Açıklama
Uzunluk/genişlik	Görüntü objesinin uzunluk ve genişliğinin oranı
Alan	Görüntü objesinin kapsadığı alan (toplam piksel sayısı)
Bütünlük	Uzunluk ve genişliğin çarpımının piksel sayısına oranı
Sınır uzunluğu	Objenin komşu objelerle olan ortak sınır uzunluğu
Asimetri	Düzenli bir çokgen biçiminden sapma
Yoğunluk	Görüntü objesinin uzunluk ve genişliğinin, nesneyi oluşturan piksel sayısına oranı
Dikdörtgen	Görüntü objesinin dikdörtgen şekline uyum oranı
Ana doğrultu	Görüntü objesinin kovaryans matrisinden türetilen özdeğere bağlı yön

Doku bir görüntü üzerindeki nesnelerin ya da bölgelerin tanımlanması için sıklıkla kullanılan önemli bir özelliktir. Doku kavramı, düzenli bir frekansta devam eden desen veya desen kombinasyonu olarak ifade edilmektedir. Bir görüntü objesinin spektral bilgilerinin dizilimi, dağılımı ve çeşitliliğinden oluşan doku özelliklerinin tanımlanması için istatistiksel yaklaşımlar kullanılmaktadır [Haralick et al., 1973], [Cömert, 2018].

Doku özelliklerinin belirlenmesinde öncelikle komşu pikseller arasındaki mesafe ve açı ilişkilerinin fonksiyonuyla hesaplanan Gri Düzey Eş Oluşum Matrisi (Grey Level Cooccurrence Matrix, GLCM) hesaplanmaktadır [Haralick et al., 1973]. GLCM bir görüntüdeki piksellerin gri seviyelerinin farklı kombinasyonlarının tekrar etme sıklığını göstermektedir [Definiens, 2006]. Gri seviyesindeki değişimin belirlenmesi için hedef piksel tanımlanır ve belirli çerçeve boyutunda (3x3, 5x5 vb.) dört yönde (0°, 45°, 90°, 135°) analiz gerçekleştirilir Şekil 4.14.



Şekil 4.14: GLCM yönleri.

Tablo 4.4'te yaygın olarak kullanılan ve tez çalışması kapsamında faydalanılan doku özelliklerine ait bilgiler verilmiştir. Tabloda yer alan eşitliklerde satır sayısı  $i$ , sütun sayısı  $j$ , matrisin  $x, y$  konumundaki pikselin normalize değeri  $P_{i,j}$  (denklem 4.13), satır veya sütun sayısı  $N$ , ortalama  $\mu$ , standart sapma  $\sigma$  sembolleri ile ifade edilmiştir.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (4.13)$$

**Tablo 4.4:** GLCM doku özellikleri.

Özellik	Formül	Açıklama
Ortalama	$\sum_{i,j=0}^{N-1} P_{i,j} \times i$	Doku düzenliliği derecesi
Standart sapma	$\sqrt{\sum_{i,j=0}^{N-1} P_{i,j} \times (i - \mu_{i,j})^2}$	Piksel gri değerleri ile ortalama arasındaki sapma
Homojenlik	$\sum_{i,j=0}^{N-1} P_{i,j} / (1 + (i - j)^2)$	Doku bütünlüğü
Kontrast	$\sum_{i,j=0}^{N-1} P_{i,j} \times (i - j)^2$	Gri seviyesi değişimine göre pikseller arası farklılık
Farklılık	$\sum_{i,j=0}^{N-1} P_{i,j} \times  i - j $	Doku kontrastı
Entropi	$\sum_{i,j=0}^{N-1} P_{i,j} \times (-\ln P_{i,j})$	Görüntüdeki pikseller arasındaki karmaşıklık
Açısal ikinci moment	$\sum_{i,j=0}^{N-1} P_{i,j}^2$	Görüntünün gri seviye dağılımı
Korelasyon	$\sum_{i,j=0}^{N-1} \frac{(i - \mu_i) \times (j - \mu_j) \times P_{i,j}^2}{\sqrt{\sigma_i^2 \sigma_j^2}}$	Komşu piksellerin gri seviyelerinin doğrusal ilişkisi

Topografik özellikler ve bunlara bağlı değişen yükseklik değerleri, AÖ /AK sınıflarının her biri için değişkenlik oluşturmaktadır. Rowe et al., çalışmalarında bitki örtüsündeki tekrarlayan örüntü yapılarının topografik özelliklerle ilişkili olduğunu ve topografik özelliklerin analizi ile doğrudan tespit edilebileceğini belirtmiştir [Rowe et al., 1994]. Ancak eğimin ve yükseltinin keskin geçişler gösterdiği yoğun kentleşmenin mevcut olduğu bölgelerde AK sınıflarının topografyadan bağımsız olarak değerlendirilmesi ve yapıların tekil yüksekliklerinin belirlenmesi gerekmektedir. Bu hedefle yüksek doğruluklu üretilen NDYM, veri setine özellik olarak eklenmiştir ve sınıflandırma sürecine dahil edilmiştir.

#### 4.2.4. Rastgele Orman

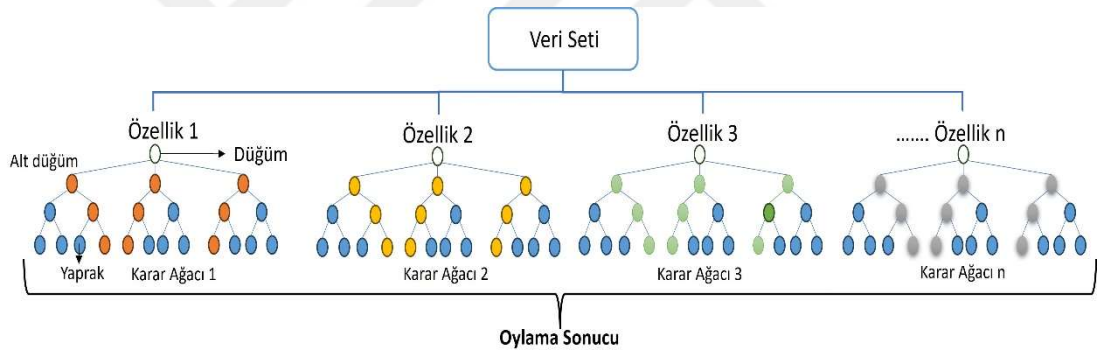
Breiman tarafından önerilen ve Cutler vd. tarafından toplu öğrenme algoritması olarak geliştirilen RF, karar ağaçlarını esas alarak çalışan sınıflandırma ve regresyon amaçlı sıklıkla tercih edilen bir yöntemdir [Modica et al., 2021], [Breiman, 2001], [Cutler et al., 2007]. RF İHA ile gerçekleştirilen çok sınıflı sınıflandırma çalışmalarında yüksek performans göstermesi, güçlü bir sınıflandırıcı olma niteliğini kanıtlaması nedeniyle literatürde popüler bir kaynak konumundadır [Feng et al., 2015], [Yuan and Hu 2016], [Sotille et al., 2022].

RF, birçok bağımsız karar ağacından oluşan bir ormanı rastgele üreten bir yöntemdir [Li et al., 2016]. Tüm ağaçlar aynı özellikleri değerlendirerek eğitilmektedir ancak orijinal veri seti bölünerek türetilen alt veri setlerinde ayrı ayrı uygulanmaktadır. Alt kümelerin 2/3'ü karar ağacının modelini oluştururken 1/3'ü modelin doğruluğunu test etmek için kullanılmaktadır [Cutler et al., 2007], [Çölkesen, 2015]. Ağaç yapısındaki modelin her bir bölümü düğüm (node) kavramını oluşturmakta ve ilk düğüm kök (root), sonuç oyu belirleyen düğümler ise yaprak (leaves) olarak adlandırılmaktadır [Bayaslı, 2021]. RF her bir bağımsız karar ağacının oluşturduğu tahmin sonucuna göre çalışmakta ve gelen tahminlere bağlı olarak sınıflandırma işlemini tamamlamaktadır. Karar ağaçlarının bağımsız olarak çalışma prensibi, varyans değerini düşürmekte ve genel hatayı azaltmaktadır. Herhangi bir görüntü objesinin sınıflandırılması işleminde, objeye ait özelliklere dayalı ağaç yapısı kurulmakta ve veri seti içerisinde yer alan herhangi bir girdi veri ormandaki tüm ağaçların belirlediği kurallara tabi tutulmaktadır. Bunun sonucunda görüntü objesi her bir ağaçtan alınan sonuca ve oy miktarına göre sınıf etiketleriyle ilişkilendirilmektedir.

Modeli oluşturan karar ağacının yapısının belirlenmesi için gereken ana parametreler; ağaç sayısı (*n<sub>tree</sub>*), maksimum ağaç derinliği ve her bir düğümde kullanılan örnek sayısıdır (*m*) [Belgiu and Draguț, 2016], [Breiman, 2001]. Bu parametrelerin optimum seçimi model performansında son derece etkilidir. Yapılan çalışmalarda, düğüm başına düşen örnek (*m*) değerinin toplam değişken sayısının karekökü olarak alınması durumunda genellikle optimum sonuçlar elde edildiği belirtilmiştir [Breiman, 2002]. Bununla birlikte bazı çalışmalar RF algoritması için belirlenen optimum değerler dışındaki çeşitli varyasyonları kıyaslamış ve sonuçlar arasında büyük çaplı bir fark olmadığını belirtmiştir [Pelletier et al., 2016], [Boulesteix et

al., 2012]. Ancak söz konusu durum veri setiyle doğrudan ilişkilidir ve parametreler için ideal değerlerin belirlenmesi son derece önemlidir.

RF en büyük ağacın üretimini hedeflemekte ve budama işlemi gerçekleştirilmeden CART (Classification and Regression Tree) algoritması ile karar ağacını büyütmektedir. Bu algoritma belirli eşik değerlerini baz almakta ve düğümleri bölerek alt düğümler oluşturmaktadır. Bölünme işlemi için Gini indeksinden faydalanılmaktadır ve homojen sınıf dağılımı tercih edilmektedir. Yüksek indeks değerli sınıflar arası heterojenliği ifade ederken düşük değerler homojenliğin göstergesidir. Düğümler arası ilişkide alt düğümün Gini indeksi üst düğümden düşük değerlere sahip olduğu durumlarda dal başarılı kabul edilir ve indeks değeri sıfıra ulaştığında yani her bir yaprakta yalnızca bir sınıf kaldığında bölünme işlemi sonlanır [Watts et al., 2011]. Şekil 4.15 RF yönteminin genel yapısını ve karar ağaçlarını oluşturan unsurları göstermektedir.



Şekil 4.15: RF algoritması ağaç yapısı ve çalışma şeması.


#### 4.2.5 Destek Vektör Makineleri

SVM'ler genellikle geleneksel yöntemlere kıyasla daha yüksek sınıflandırma doğruluğu sağlamaları sebebiyle uzaktan algılama aracılığıyla temin edilen çok bantlı verilerin AÖ/AK analizinde sıklıkla tercih edilmektedir [Mantero et al., 2005], [Mercier and Lennon, 2003]. Parametrik sınıflandırıcılarda amaç her sınıfın özelliklerini ya da dağılımı belirlemektir. SVM bunun aksine eğitim verisine odaklanmakta ve mevcut sınıfların ayrımı için ideal hiper düzlemin bulunması hedefiyle çalışan, parametrik olmayan istatistiksel bir algoritmadır [Mountrakis et al., 2011]. Hiper düzlem sınırına en yakın örnek veriler esas alınmakta ve bu örnekler

yönteme adını veren destek vektörleri olarak adlandırılmaktadır [Maxwell et al., 2018]. Girdi verilerin analizinde, iki boyutlu uzayda doğrusal, üç boyutta düzlemsel ve çok boyutlu uzay içinse hiper düzlemlerden yararlanılmaktadır [Güran et al., 2014]. Modelin temel amacı, sınıflar arası ayrımı sağlayacak optimal hiper düzlemi tasarlamak yani farklı sınıflar arasındaki destek vektörleri arasındaki mesafeyi üst sınırdan belirleyebilmektir. Hiper düzlemin belirlenmesinde Eşitlik 8’de bulunan ağırlık vektörü ( $w$ ), örnek veriye ait bilgi ( $x$ ) ve eşik değeri ( $b$ ) kullanılmaktadır. Burada  $w$  (hiper düzlem normali) ve  $b$  değeri iki sınıf arasındaki maksimum mesafeyi ( $2/\|w\|$ ) koruyacak şekilde belirlenmektedir [Ben-Hur and Weston, 2010]. Maksimum mesafe, her sınıfın en yakın noktasından hiper düzleme olan mesafenin toplamını ifade etmektedir [Vapnik, 1998].

$$w \cdot x + b = 0 \quad (4.14)$$

Şekil 4.16 denklem 4.14’e göre belirlenen hiper düzlem ile iki sınıflı bir veri kümesi için sınıflandırma işlemini temsil etmektedir. Bu örneğe göre  $w \cdot x_i + b > 0$  için tüm değerler ikinci sınıfla,  $w \cdot x_i + b < 0$  için tüm veriler birinci sınıfla ilişkilendirilecektir.



Şekil 4.16: İki sınıflı veri seti için SVM ile hiper düzlemlerin belirlenmesi.


SVM temelde iki farklı sınıf için tek bir ayırım düzlemi gerçekleştirerek çalışmaktadır. Bunun yanı sıra sınıflandırıcı olası her bir sınıf kombinasyonu için bu işlemi gerçekleştirerek çok sınıflı bir yapının ayrımını da sağlayabilmektedir [Cortes

**and Vapnik 1995]**. Bu işlem için One Against All (OAA) ve One Against One (OAO) olarak adlandırılan iki yöntem bulunmaktadır. İki sınıfın ayırımında belirlenen fonksiyon temel prensip olarak kabul görmekte ve her ikili sınıf grubu için uygulanmaktadır. OAO çok sınıflı bir analizde, problemi birden fazla ikili sınıflandırma olarak bölmekte ve her sınıf çifti başına SVM oluşturmaktadır.

OAO yöntemi veri setindeki her bir sınıf üyesi için diğer sınıfla ayırımını belirleyen SVM kullanılmaktadır. Bu yaklaşımda üçüncü ya da daha fazla sınıflı çalışmalarda mevcut diğer sınıflar ihmal edilir ve yalnızca iki sınıf odaklı hiper düzlem belirlenir **[Hsu and Lin, 2002]**. Denklem 4.15'te sınıf sayısının ( $m$ ) kullanımıyla SVM sayısının hesabı ifade edilmiştir. Bu yöntemde sınıf sayısı arttıkça sınıflandırıcı sayısının da artması gibi ciddi bir dezavantaj ortaya çıkmaktadır **[Pal, 2005]**.

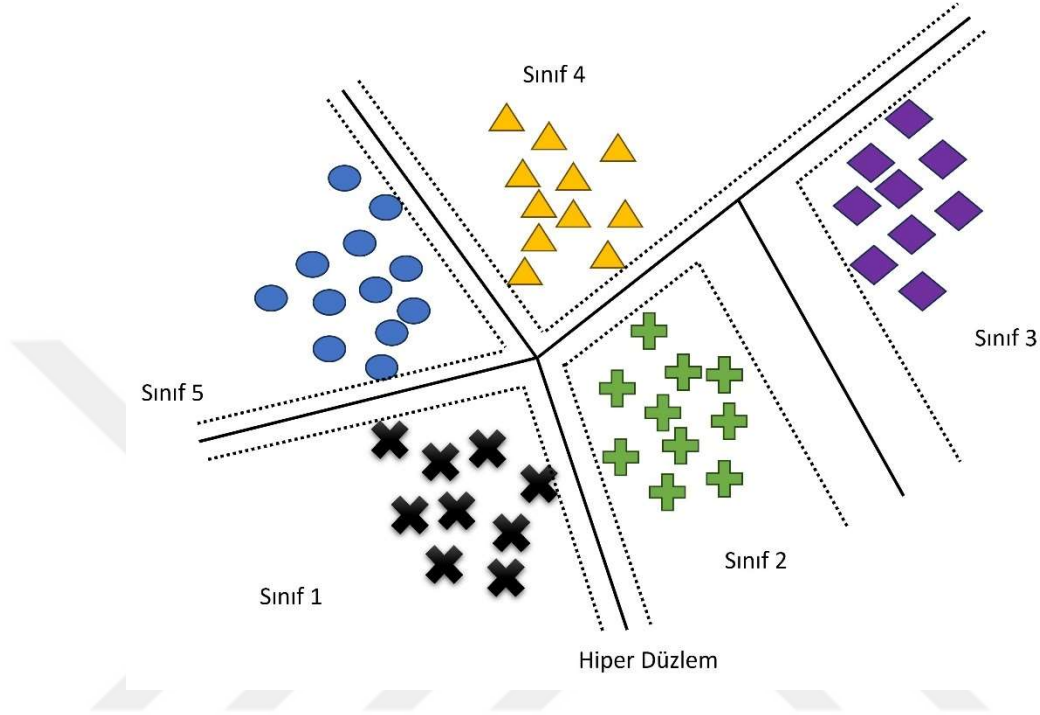
$$\frac{m(m-1)}{2} \quad (4.15)$$

OAA yöntemi ise bir sınıf ile geri kalan tüm sınıfları ayırmak üzere bir hiper düzlem belirlemektedir. Tek aşamalı olarak ideal hiper düzlemin oluşumu hedeflenmektedir. Sınıf sayısı ( $m$ ) kadar SVM oluşturulmaktadır. **Şekil 4.17'**de bu iki yöntemin üç sınıflı bir veri seti için ürettiği hiper düzlemlere ait örnek gösterilmektedir. Yöntemin yüksek bellek ihtiyacı ve veri kümelerindeki sınıf sayısının çok olduğu durumlardaki performansı temel sorunlarını oluşturmaktadır **[Huang et al., 2002]**, **[Pal, 2005]**. OAO yönteminde işlemler uzun zaman almasına rağmen OAA'ya kıyasla daha doğru sonuçlar üretmektedir.



**Şekil 4.17:** OAO ve OAA yöntemiyle belirlenen hiper düzlemler.

**Şekil 4.18'**de SVM'nin beş sınıflı bir veri seti için ürettiği nihai sınıflandırmaya ait örnek görsele yer verilmiştir. Beş sınıflı bir veri kümesi için optimum hiper düzlemler belirlenir ve sınıflandırma tüm verilerin maksimum mesafe ile ayrımı sağlandığında sonlanır.



**Şekil 4.18:** Çok sınıflı veri seti için SVM ile hiper düzlemlerin belirlenmesi.

SVM yöntemi başlangıcında doğrusal ayırım üzerine tasarlanmıştır. Düşük hacimli, az sınıflı veri kümelerinin analizinde doğrusal yaklaşımlar başarılı sonuçlar üretebilmektedir. Ancak veri boyutu ve değişkenlerin çok sayıda olduğu uzaktan algılama veri setlerinde doğrusal ayırımın performansı yetersiz kalmaktadır. Bu noktada doğrusal ayırım için kabul görmüş eşitlikler, çekirdek (Kernel) fonksiyonları ile geliştirilerek, girdi veriler boyut arttırımı ile çok boyutlu uzayda değerlendirilmekte ve daha tutarlı sonuçlar üretilebilmektedir.


Modelin oluşumu için tercih edilecek çekirdek (kernel), analiz sonuçları üstünde son derece etkindir, sınıflandırmada yüksek doğruluk için SVM sınıflandırıcısı için ideal çekirdek ve parametrelerinin veri setine en uygun değerleri alması gerekmektedir [Zafari et al., 2019]. Literatürde birçok çekirdek bulunmakta ve çok sınıflı çalışmalarda hiper düzlemlerin tasarımı için doğrusal olmayan Radyal Tabanlı Fonksiyon (RTF) yaygın olarak tercih edilmektedir [Kavzoglu and Colkesen, 2009].

Tez çalışması kapsamında kullanılan veri seti için lineer çekirdek tercih edilmiştir ve RTF'ye kıyasla daha yüksek model doğruluğu elde edildiği görülmüştür.

SVM için model oluşumunda düzenleme parametresi (c) ve gamma değeri olmak üzere iki temel parametre bulunmaktadır. C değeri kullanıcı tarafından tanımlanmakta ve model hatasında doğrudan etkili olmaktadır. Bu değişkenin tanımlanmasında yüksek değerlerin seçimi daha kompleks ayırım düzlemleri oluşturmada, genellemeyi azaltmada ve modelin farklı veri setlerinde uygulanabilirliğini zorlaştırmaktadır [Maxwell et al., 2018].

#### 4.2.6. Aşırı Gradyan Artırma (XGBoost)

Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost), Chen and Guestrin tarafından Gradyan Artırma yönteminin iyileştirilmesine dayalı ortaya koyulan birçok çalışma alanı için başarılı sonuçlar üretmiş, gelişmiş bir toplu öğrenme algoritmasıdır [Ma et al., 2021], [Chen and Guestrin, 2016]. XGBoost öncelikli olarak ağaç yapılı zayıf modellerin tasarlanmasıyla işlem sürecine başlamakta ve sonuç çıktılar arasında yer alan hata skorunu baz alarak, iteratif şekilde model tutarlılığını iyileştirme odaklı çalışmaktadır. Bu çalışma prensibinde, iteratif üretilen karar ağaçları içerisinde ilk üretilen ağacın eğitim ve tahmin sonuçları sonraki karar ağacı yapısının oluşumunda etkili olmaktadır Şekil 4.19. Her sınıflandırıcı kendinden önceki model yapısının düşük performans gösterdiği bölgeleri dikkate almakta ve ağırlık artırımı yoluyla bu alanların doğru çıkarımı üzerine yoğunlaşmaktadır [Budholiya et al., 2022]. Model her ağaca ait tahminleri paralel olarak hesaplamakta ve son aşamada tahmin sonuçları birleştirilmektedir [Yao et al., 2022].



Şekil 4.19: XGBoost çalışma şeması.

Veri setinin  $D = (x; y)$ ,  $|D| = n$ ,  $(x \in R^m, y \in R)$  şeklinde tanımlandığını varsaydığımız durumda,  $m$  özellik sayısına,  $n$  örnek sayısına karşılık gelmektedir. Eşitlik 4.16 model tarafından tahmin edilen değeri ( $\hat{y}_i$ ) ifade etmektedir.  $f_k$  bağımsız karar ağaçlarını,  $f_k(x_i)$   $k$  numaralı ağaçtan  $i$  numaralı örnek veriden üretilen tahmini ifade etmektedir.  $k$  değeri toplam ağaç sayısına karşılık gelmektedir, girdi veri  $x$  ve olası tüm ağaçlar  $F$  ile temsil edilmektedir (Denklem 4.16).

$$\hat{y}_i = \sum_{k=1}^k f_k(x_i), \quad f_k = F \quad (4.16)$$

XGBoost algoritmasının hedef fonksiyonu ( $L(\Phi)$ ) iki bölümden oluşmaktadır. İlk bölüm, test kümesinde yer alan verilerin tahmin edilen değeri ( $\hat{y}_i$ ) ile gerçek değeri ( $y_i$ ) arasındaki farkı belirleyen eğitim kaybı fonksiyonudur (Denklem 4.17). İkinci bölümü ise regülarizasyon ( $\Omega(f)$ ) oluşturmakta ve aşırı öğrenmenin kontrolünün yanı sıra model kompleksliğini de düzenleyen önemli bir aşamadır.

$$L_k = \sum_{i=1}^n l(\hat{y}_i, y_i) \quad (4.17)$$

$$L(\Phi) = \sum_{i=1}^n l(\hat{y}_i, y_i) + \sum_{k=1}^k \Omega(f_k) \quad (4.18)$$

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (4.19)$$

Denklem 4.19'da  $\gamma$  her bir yaprak için kompleksliği, T ağaç yapısındaki toplam yaprak sayısını,  $\lambda$  düzeltmede kullanılan cezalandırma katsayısını,  $\|w\|$  yaprak ağırlıklarını ifade etmektedir. XGBoost algoritmasında, hedef fonksiyonun optimizasyonu için kademeli azalma yöntemi kullanılmaktadır. Hedef fonksiyonun minimum değerlere ulaşması, tahmin sonucuna göre yeni bir ağaç oluşturan iterasyon işlemi ile gerçekleşmektedir ve her iterasyon sonrası oluşan hedef fonksiyonu Denklem 4.20'deki gibidir. Bu eşitlikte t değeri iterasyon numarasını ve  $\hat{y}_i^{(t)}$  t iterasyonundaki tahmin değerini temsil etmektedir. Model hedefini minimize etmek için yeni bir  $f_t$  fonksiyonunun eklenmesi gerekmektedir.

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (4.20)$$

Model optimizasyon hızının arttırımı için hedef fonksiyonu Denklem 4.21'de açıklanan Taylor açılımı kullanılarak sadeleştirilmekte ve sabit terim kaldırılmaktadır. Burada  $g_i$  ve  $h_i$  ifadeleri kayıp fonksiyonun birinci ve ikinci dereceden gradyan değerini ifade etmektedir.

$$f(x + \Delta x) = f(x) + f(x)' \Delta x + f(x)'' \Delta x, \quad \Delta x = f_t(x_i) \quad (4.21)$$

$$L^{(t)} = \sum_{i=1}^n [l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (4.22)$$

$$g_i = \partial_{\hat{y}_i^{(t-1)}} l((y_i, \hat{y}_i^{(t-1)})), \quad h_i = \partial_{\hat{y}_i^{(t-1)}}^2 l((y_i, \hat{y}_i^{(t-1)})) \quad (4.23)$$

$$L^{(t)} = \sum_{i=1}^n [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (4.24)$$

Karar ağacı parametreleri ve  $\Omega$  ifadesinin açılımı hedef fonksiyonda yerine koyularak Denklem 4.25 elde edilmektedir.  $\omega_j^*$  ifadesi j yaprağı için optimum ağırlık değerinin hesabında kullanılmaktadır. Denklem 4.27 ağaç yapısının kalitesinin ölçülmesi için belirlenen fonksiyonu göstermektedir. Ağaç yapısı bu eşitlikler (4.25-4.27) yardımıyla değerlendirilerek kurulmaktadır ancak tüm ağaç kombinasyonlarının eş zamanlı analizi mümkün olmadığından iteratif sonuçlar sırayla incelenmektedir.

$$L^{(t)} = \sum_{j=1}^T \left[ \left( \sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left( \sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \quad (4.25)$$

$$\omega_j^* = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (4.26)$$

$$L^{(t)} = -\frac{1}{2} \sum_{j=1}^T \frac{(\sum_{i \in I_j} g_i)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (4.27)$$

Veri setinin alt örneklere bölünmesiyle aşırı öğrenmenin önüne geçilmesi ve iteratif ağaç üretimi ile yüksek performans sağlanmasına rağmen XGBoost algoritması için optimum parametrelerin belirlenmesi gerekmektedir [Budholiya et al., 2022]. İterasyon sayısı, maksimum ağaç derinliği, rastgele örnek oranı ve öğrenme oranı sınıflandırma sonucunda doğrudan etkili olan temel parametreler arasında yer almaktadır. Hiper parametre optimizasyonu için mevcut yöntemlerin desteğiyle bu parametreler için en uygun değerler belirlenebilmektedir.

#### 4.2.7. GridsearchCV

Sınıflandırma işlemleri için faydalanılan makine öğrenmesi algoritmaları çeşitli eşitlikler üzerine inşa edilmektedir. Model performansları, bu eşitliklerde yer alan sabitlerin yanı sıra değişkenlerin aldığı değerlerle doğrudan ilişkilidir. Eğitim verisinin doğru bir şekilde analiz edilebilmesi, en iyi modelin tasarlanabilmesi ve sonuç ürünlerin doğruluğunda maksimum değerlere ulaşılabilmesi hedefiyle bu parametreler için optimum değerlerin belirlenmesi ihtiyacı oluşmaktadır. Kullanıcı tarafından tanımlanan bu değerler hiper parametre olarak adlandırılmaktadır ve tez çalışma kapsamında modeller için en uygun hiper parametre değerleri Gridsearch yöntemi yardımıyla elde edilmiştir.

Gridsearch hiper parametre alternatiflerinden en uygun seçeneklerin belirlenmesi için deneme yanılma yaklaşımını otomatikleştiren bir optimizasyon tekniğidir [Malakouti et al., 2023]. Her bir parametre için belirlenen aralık ve artış miktarına bağlı kalarak birçok kombinasyon oluşturmaktadır. Tüm kombinasyonlarla oluşturduğu modeller için çapraz doğrulama skoru hesaplamakta ve en yüksek doğruluğa sahip kombinasyonu en iyi parametre değeri olarak kullanıcıya sunmaktadır [Pedregosa et al., 2011]. Model performansının belirlenmesinde korelasyon katsayısı ( $R^2$ ), ortalama hata karesi (mean square error, MSE), karesel ortalama hata (root mean square, RMSE), ortalama mutlak hata (mean absolute error, MAE) değerleri kullanılmıştır ve

bu değerlendirme kriterleri Denklem 4.28-4.31’de sunulmuştur.  $y_i$  bilinen,  $\hat{y}_i$  tahmin edilen değer,  $\bar{y}_i$  bilinen değerlerin ortalamasını ve  $n$  örnek sayısını ifade etmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (4.28)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (4.29)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (4.30)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (4.31)$$

Başlangıç parametreleri için değer aralığının kullanıcı tarafından tanımlanması, bu yöntemin önemli bir dezavantajını oluşturmaktadır. Optimum değer aralığı ya da algoritma yapısının içerdiği yöntemlerin seçimi kullanıcının tecrübe ve bilgisi ile sınırlı kalmaktadır.

#### 4.2.8. Özellik Seçimi

Çok sayıda veri kaynağının ya da yardımcı veri setlerinin bütünleşik kullanıldığı çalışmalarda, her bir özellik sonuç üzerinde pozitif ya da negatif etkiye sahip olmasının yanı sıra etkisiz konumda da olabilmektedir. Model karmaşıklığını azaltmak, en doğru sınıflandırma için işlem yükünü dengelemek ve optimum performansa ulaşmak için sonuç üzerinde doğrudan etkiye sahip olan özelliklerin belirlenmesi gerekmektedir. Böylelikle kurulacak modelin veri setine karşı duyarlılığı azaltılmakta ve farklı veri setleri için uygulanabilirliği olanaklı hale gelmektedir.

Özellik seçimi veri madenciliği [Beniwal and Arora, 2012], makine öğrenmesi [Cai et al., 2018], görüntü işleme [Bolon-Canedo and Remeseiro, 2020], hiperspektral görüntü analizi [Colkesen and Kavzoglu, 2016], [Kavzoglu et al., 2018] gibi birçok çalışma alanında kullanılmaktadır. Bu çalışmada sınıflandırma sürecine dahil olan her bir özelliğin tekil etkisi belirlenerek, veri setini en iyi şekilde temsil eden, düşük korelasyonlu özelliklerin tespiti amacıyla özyinelemeli özellik seçimi yöntemi tercih edilmiştir. Bu yöntem önem derecesine göre özelliklerin sıralanması ve düşük öncelikli özelliklerin tekrarlı bir şekilde elimine edilmesi esasına dayanarak çalışmaktadır. Tüm veri kümesinin değerlendirilmesiyle başlayan süreç düşük etkiye

sahip özelliğın bulunup veri kümesinden çıkarılmasıyla devam etmektedir. Yöntemin uygulanmasında, seçilecek özellik sayısına ilişkin sınır değerin tanımlanması ve herhangi bir eşik değeri olmadan tüm verilerin değerlendirilerek, veri seti çerisindeki en uygun özellik kümesinin belirlenmesi olmak üzere iki farklı yaklaşım mevcuttur. Tez kapsamında, yüksek performans gösteren özelliklerin belirlenmesinde, eşik değerinin kullanıcı tarafından tanımlanmadığı ve çapraz doğrulama esasıyla yüksek skor üreten veri kümesinin oluşturulmasına dayanan ikinci yöntem uygulanmıştır.

#### 4.2.9. Doğruluk Analizi

Uzaktan algılama, çeşitli temaların haritalanmasında yüksek performanslı sonuçlar ortaya koyabilmesine rağmen sıklıkla hatalı sonuçların üretiminde de pay sahibidir [Foody, 2004]. Sonuç haritalardaki mevcut hatalar çok düşük miktarda olabileceği gibi ciddi oranlara da ulaşabilmektedir. Bu sebeple tematik hata doğruluğunun ölçülmesi ve belirlenmesi gerekmektedir. Tematik haritalardan faydalanacak kullanıcılar, mevcut haritanın hangi amaçlar için kullanılabileceğine karar verme noktasında, doğruluk ölçütüne bağlı olarak bir yaklaşım gösterebilmektedir. Benzer şekilde tematik haritanın üretiminde de üreticinin sonuç ürünün doğruluğu hakkında bilgi sahibi olabilmesi durumunda, performans artırımı için üretim aşamalarını yeniden gözden geçirebilecektir. Günümüzde, bu sebeplerden ötürü bir sınıflandırma sonucunun herhangi bir amaçla kullanılabilmesi için öncelikle doğruluk analizinin tamamlanması zorunluluğu yerine getirilmelidir.

Doğruluk analizi sonuç ürünlerin kalitesinin değerlendirilmesi ve üretim performansı hakkında fikir sağlanabilmesi açısından son derece önemlidir [Richards, 2013]. Çeşitli yöntem ve veri setinin karşılaştırmalı olarak değerlendirildiği bu çalışmada, doğruluk analizi bölümü sağladığı istatistiki bilgiler ile AÖ/AK haritalamada en uygun yaklaşımın kararı noktasında efektif bir işlem adımıdır.

Tematik harita doğruluğunun analizi için öncelikli olarak referans veri ihtiyacı karşılanmalıdır. Referans veri kaynağı olarak yüksek çözünürlüklü ortomozaik verinin altlık olarak kullanılması ve vektörizasyon işlemiyle elde edilen veriler değerlendirilmiştir. Tez çalışması kapsamında üretilen tematik haritalarının doğruluk değerlendirmesinde hata matrisi (Şekil 4.20) ve bu matristen türetilen; üretici doğruluğu (producer accuracy, PA), kullanıcı doğruluğu (user accuracy, UA) genel

doğruluk (overall accuracy, OA) ve F1 skor gibi doğruluk metrikleri baz alınmıştır [Congalton and Green, 1999].

		Referans (j= sütun)			Satır toplamı	
		1	2	k	$n_{i+}$	
Sınıflandırma (i= satır)	1	$n_{11}$	$n_{12}$	$n_{13}$	$n_{1+}$	
	2	$n_{21}$	$n_{22}$	$n_{23}$	$n_{2+}$	
	k	$n_{k1}$	$n_{k2}$	$n_{kk}$	$n_{k+}$	
Sütun toplamı		$n_{+j}$	$n_{+1}$	$n_{+2}$	$n_{+k}$	$n$

Şekil 4.20: Örnek hata matrisi.

Şekil 24'te gösterilen matris elemanları sınıflandırma sonuçları (i) ve referans veriler (j) arasındaki ilişkiyi temsil etmektedir.

$$PA = \frac{n_{jj}}{n_{+j}} \quad (4.32)$$

$$UA = \frac{n_{ii}}{n_{i+}} \quad (4.33)$$

$$OA = \frac{\sum_{i=1}^k n_{ii}}{n} \quad (4.34)$$

F1 skor kesinlik ve hassasiyet değerlerinin harmonik ortalamasıdır ve sınıf bazında doğruluk değerlendirmesi için yaygın olarak kullanılmaktadır. F1 skor hesabında Denklem 4.35-4.36'da verilen kesinlik (precision, P) ve duyarlılık (Recall, R) kavramları yer almaktadır. Duyarlılık ve kesinlik değerleri doğru pozitif (true positive, TP), yanlış pozitif (false positive, FP) ve yanlış negatif (false negative, FN) kavramlarından oluşmaktadır. Doğru pozitif, herhangi bir sınıfa ait pozitif örneğin doğru sınıf etiketi ile ilişkilendirildiği durumu temsil etmektedir. Doğru negatif, herhangi bir sınıfa ait negatif örneğin doğru sınıf etiketi ile ilişkilendirildiği durumu ifade ederken, yanlış negatif ise yanlış sınıf etiketiyle ilişkilendirildiği durumu betimlemektedir. Buradaki pozitiflik kavramı, o sınıfa ait örneğin gerçekte o

konumdaki varlığını ifade etmektedir. Negatiflik kavramı ise sınıfın gerçekte o konumda mevcut olmadığı durumu belirtmektedir.

$$P = \frac{TP}{TP + FP} \quad (4.35)$$

$$R = \frac{TP}{TP + FN} \quad (4.36)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (4.37)$$



## 5. UYGULAMA VE BULGULAR

Tezin bu bölümünde, metodoloji kısmında açıklanan tüm teorik bilgilerin saha ve ofis bölümündeki uygulamaları ve sonuç ürünlerin analizinden elde edilen bulgular sunulmuştur. Ortomozaik ve NDYM üretim aşamaları, çıktı ürünlerle birlikte detaylı bir şekilde irdelenmiş ve her bir adımdaki parametreler hakkında bilgi verilmiştir.

RF, SVM ve XGBoost algoritmaları ile üretilen raster formatlı tematik harita sonuçları ve doğruluk analizlerinin grafik gösterimi tüm veri setleri için sunulmuştur. Bu grafikler baz alınarak tüm sınıfların çıkarımına dair doğruluk oranları ayrı ayrı incelenmiştir. SHAP analizi ile tematik harita üretiminde en yüksek etkiye sahip özellikler belirlenmiş ve buna ek olarak tüm sınıfların bireysel çıkarımında öne çıkan özellikler de ayrıca tespit edilmiştir. Son olarak tüm bulgular derlenmiş ve NDYM verisinin eklenmesiyle oluşturulan yaklaşımın tüm sınıflandırıcılar için başarı oranını arttırdığı net bir şekilde ortaya konmuştur.

### 5.1. Görüntü Alımı

İHA ile çalışma alanına ait verilerin alınmasında: bölge sınırlarının belirlenmesi, uçuş planının hazırlanması, yer kontrol noktalarının (YKN) tesisi ve uçuş işlemleri sırasıyla gerçekleştirilmiştir. **Tablo 5.1.** veri alımı gerçekleştirilen İHA'nın teknik özelliklerini ifade etmektedir. Tüm sensörler simultane şekilde çekim işlemi gerçekleştirerek bir adet .jpg (RGB) ve beş adet .tiff formatlı görüntüyü, üzerinde bulunan hafıza kartına işlemektedir. Özellikle kırmızı-kenar ve yakın kızılötesi bantları, bitki örtüsünün çıkarımında ve türler arası sınıflandırmada çeşitli indislerle üretilen değerlerle birlikte sınıflandırma sonuçlarına önemli katkılar sağlamaktadır [**Lefebvre et al., 2019**], [**Pontoglio et al., 2021**].

**Tablo 5.1:** DJI Phantom 4 Multispektral İHA teknik özellikler.

Sensör Özellikleri		Cihaz Özellikleri	
CMOS	1 / 2.9 – 2.08 Megapiksel	Uçuş süresi	27 dk.
Görüntü çözünürlüğü	1600 x 1300	Çalışma sıcaklığı	0°C – 40°C
Odak uzaklığı	5.74mm	GNSS	GPS-GLONASS Galileo
Mavi	450 nm + 16nm	Hover doğruluğu	<u>RTK etkin</u> D ± 0.1m Y ± 0.1m <u>RTK devredışı</u> D ± 0.1m Y ± 0.3m (görüş) D ± 0.5m Y ± 1.5m (gnss)
Yeşil	560 nm + 16nm	Ağırlık	1487 g
Kırmızı	650 nm + 16nm	Konum Doğruluğu (RTK)	D 1.5 cm + 1 ppm Y 1 cm + 1 ppm
Kırmızı-Kenar	730 nm + 16nm		
Yakın kızılötesi	840 nm + 26nm		

Çalışma hedefleri doğrultusunda bu bantlardan elde edilecek verilerin son derece büyük öneme sahip olmasından dolayı, görüntü alımında yansıtımın en yüksek değerlere ulaştığı yaz dönemi, hava şartlarının güvenli uçuşa uygun ortam sağladığı ve gölge boyunun ideal olduğu saat aralığında görüntü alım işlemi gerçekleştirilmiştir. İHA üzerindeki algılayıcılar tarafından nesnelere yansıyan enerjinin (reflektans) objektifte en doğru şekilde toplanabilmesi ve kaydedilebilmesi için kamera bakış açısı 90° (nadir) olarak belirlenmiştir **Şekil 5.1**. Bu şekilde yeryüzünden objektife ulaşan ışınlar minimum veri kaybıyla kayıt altına alınabilmiştir.



**Şekil 5.1:** Görüntü alımı kamera açısı.

Uçuş planı, DJI tarafından kullanıcıya sunulan, yer istasyonu yazılımı (Ground Station Pro) kullanılarak Kuzey-Güney yönlü poligonal uçuş olarak belirlenmiştir. Çalışma alanı sınırları belirlenirken bina, yol, vejetasyon, sulak alan gibi çeşitliliği arttıran heterojen unsurların yer almasına özen gösterilmiştir. Google Haritalar yardımıyla uçuş planı altlığı oluşturulmuş ve çalışma alanına ait sınır noktalar işaretlenerek uçuş rotası oluşturulmuştur **Şekil 5.2**.



**Şekil 5.2:** İHA Uçuş planı.

Cihazın batarya donanımına bağlı olan maksimum uçuş süresi göz önünde bulundurularak, çalışma alanının İHA ile görüntülenmesi ardışık iki ayrı uçuş ile gerçekleştirilebilmiştir. Görüntüler arası boyuna %80 ve enine %60 bindirme oranı kullanılmıştır. Ardışık gerçekleştirilen iki ayrı uçuşta, örtüşen kolonlarda belirlenen bu bindirme oranının korunması dikkate alınmıştır. Çalışma alanının geniş yüzölçümü, yüksek yapıları içermesi gibi sebeplerle uçuş yüksekliği 110 m olarak belirlenmiş ve YÖA ~ 6 cm olarak elde edilmiştir. İki ayrı uçuş sonucunda toplam 4208 görüntü alınmıştır.

DJI marka İHA Gerçek Zamanlı Kinematik (Real Time Kinematic, RTK) ekipmanına sahip olması sebebiyle GNSS istasyonuna bağlanarak, YKN tesisine ihtiyaç duymadan cm düzeyinde 3B konum doğruluğunu kullanıcıya sağlayabilmektedir. Ancak uçuş sırasında yaşanabilecek bağlantı problemlerine karşı ve uçuş işlemi sonrasında

görüntülerin yöneltilmesi, hassas georeferanslandırma, 3B modelin yüksek kalitede üretimi ve sonuç ürünün BDN yardımıyla doğruluk kontrolü için sekiz adet 1m x 0.25m boyutunda mobil polikarbon YKN tesis edilmiştir. Bu noktaların tesisinde; homojen dağılım, gölge alanlar, ağaç çevresi, araç trafiği, yükselti gibi unsurların problem teşkil etmesi sebebiyle bu vb. kriterler dikkate alınarak zemin kotlu açık alanlara tesis edilmelerine özen gösterilmiştir **Şekil 5.3**.



**Şekil 5.3:** Polikarbon yer kontrol noktası örneği.

YKN'lerin koordinatlandırma işlemi uçuş öncesinde CHC i80 GNSS alıcısı ile RTK yöntemi kullanılarak WGS84-UTM35N projeksiyon sistemine bağlı olarak, yüksek hassasiyette gerçekleştirilmiştir **Tablo 5.2**. Dikdörtgen şekilli iki ayrı kanattan oluşan YKN parçalarının birleşim bölgesi, daire ile sınırlandırılmış siyah renk ile boyalıdır. İnsan gözünün yuvarlak nesnelere orta noktasını algılama kabiliyeti göz önünde bulundurularak koordinat ölçümü tam orta nokta üzerinden gerçekleştirilmektedir. Böylelikle yüksek irtifadan alınan fotoğraflar üzerindeki orta nokta işaretleme işleminde maksimum uyum yakalanmıştır.

**Tablo 5.2:** CHC i80 GNSS alıcısı teknik özellikler.



**CHC i80**


<b>Teknik özellikler</b>	
GNSS teknolojileri	GPS, BeiDou GLONASS Galileo and SBAS
İşletim sistemi	Linux
RTK yatay doğruluk	8 mm + 1 ppm RMS
RTK düşey doğruluk	15 mm + 1 ppm RMS
Post-processing yatay doğruluk	2.5 mm + 0.5 ppm RMS
Post-processing düşey doğruluk	3.5 mm + 0.5 ppm RMS
Modem - bluetooth	4G, 3G, GSM
Hafıza	32 GB

İHA'nın güvenli kalkış-iniş alanı için belirli çaptaki engellerden uzak ve düz topografyaya sahip alan üzerine iniş pedi tesis edilmiştir **Şekil 5.4**. Uçuş planının ve arazi çalışmalarının tamamlanmasının ardından, toplamda 40 dakika süren iki uçuş gerçekleştirilmiştir ve 4212 adet hava fotoğrafının alımı tamamlanmıştır. Saha çalışmasının ardından tüm görüntüler ofis ortamında kontrol edilmiş ve fotogrametrik ürünlerin üretimi için uygun formatta depolanmıştır.



**Şekil 5.4:** İHA iniş – kalkış alanı.


**Şekil 5.5** görüntü alım anındaki kamera konumunu ve bindirmeli olarak çekilen alanların kapsandığı fotoğraf sayısını göstermektedir. Çalışma sınır hattı ve çevresinde beş fotoğraf ile bindirmeli alanlar korunurken alanın geneli incelendiğinde 3B ürünlerin üretimi için dokuz fotoğrafın sağlandığı görülmektedir.



**Şekil 5.5:** Görüntü alım anındaki kamera konumları ve bindirmeli alanlardaki fotoğraf sayısı.


## 5.2. Ortomozaik Üretimi

Agisoft, görüntülerin iç ortamına aktarılması sonrasında SFM algoritması tabanlı çalışarak kullanıcıya yoğun nokta bulutu üretimi için olanak sağlayan bir yazılımdır [Mancini et al., 2013]. Yoğun nokta bulutu üretimi öncesinde SFM algoritması ile görüntülerin karşılıklı yöneltmesi ve iç yöneltme parametrelerinin ( $f$ ,  $c_x$ ,  $c_y$ ) yeniden hesaplanması, otomatik ve eş zamanlı olarak gerçekleştirilmiştir **Şekil 5.6**.



**Şekil 5.6:** Yöneltme işlemleri tamamlanmış hava fotoğrafları.

Görüntülerin yöneltilmesinde özellik çıkarımı algoritmaları ile belirlenen çok sayıdaki bağlama noktasından faydalanılmıştır. Khoshelham, çalışmasında bağlama noktalarını kullanarak gerçekleştirdiği yöneltilme işlemi neticesinde bu noktaların sayılarının belirli düzeyde tutulmasıyla yapılan uygulamalarda, model hatasının düşürülebileceği sonucuna varmıştır [Khoshelham, 2009]. Bu bilgi doğrultusunda yazılım tarafından varsayılan limit değerleri (40.000 anahtar nokta, 4000 bağlama noktası) kullanılarak toplamda 1.803.491 adet bağlama noktası elde edilmiş ve yöneltilme işleminde değerlendirilmiştir. Görüntü eşleştirme işleminin ardından ortomozik üretimi için ihtiyaç duyulan nokta bulutunun ön aşaması olan seyrek nokta bulutu (sparse cloud) üretimi tamamlanmıştır **Şekil 5.7**.



**Şekil 5.7:** Çalışma alanını kapsayan seyrek nokta bulutu.

Çalışma kapsamında RTK donanımına sahip İHA kullanılması sebebiyle mutlak yöneltilme sonuçlarının cm mertebesinde doğrulukta elde edilmesi beklenmektedir. Ancak önceki kısımlarda belirtilen yüksek doğrulukta model üretimi ve model doğruluğunun bağımsız denetim noktaları ile analizi gibi hedefler doğrultusunda sekiz adet YKN tesisi ve ilgili noktaların koordinat ölçümü gerçekleştirilmiştir. Kontrol noktaları için yer seçiminde radyal dağılıma dikkat edilmiştir **Şekil 5.8**.



**Şekil 5.8:** YKN'lerin çalışma alanı üzerindeki dağılımı.

Mutlak yöneltme sonrasında her YKN'ye ait KOH bilgisi **Tablo 5.3**'te gösterilmiştir. Tüm YKN'lerin yöneltme işlemine dahil edildiği, rölatif model doğruluğunu ifade eden **Tablo 5.3** incelendiğinde, tüm noktalarda piksel altı doğruluk hedefinin sağlandığı görülmektedir ve rölatif model doğruluğu 1.5 cm olarak hesaplanmıştır.

**Tablo 5.3:** YKN'lere ait koordinatlar ve hesaplanan konum doğruluğu.

YKN	X (m)	Y (m)	Z (m)	KOH (m)	Ortalama KOH (m)
1	4519551.723	446080.035	46.353	0.002	
2	4519505.104	446258.296	45.961	0.019	
3	4519725.644	446390.207	47.367	0.030	
4	4519648.496	446186.873	46.795	0.013	0.015
5	4519831.690	445925.637	47.363	0.006	
6	4519692.207	445662.163	45.329	0.004	
7	4519570.695	445839.910	45.257	0.013	
8	4519816.588	445741.211	46.911	0.011	

**Şekil 5.9** kontrol noktalarının dağılımını ve hata elipslerini göstermektedir. Maksimum hatanın 6 mm gibi düşük bir değerde korunduğu ve genel dağılımın çalışma için ihtiyaç duyulan doğruluk seviyesinde seyrettiği görülmüştür.



**Şekil 5.9:** YKN dağılımı ve hata elipsleri.

**Tablo 5.4**'te YKN'lerden üç adeti (1, 5, 8) BDN olarak kullanılmış ve mutlak model doğruluğu hesaplanmıştır. Bu noktaların seçiminde modelin genelini ifade etmesi amacıyla radyal dağılıma önem gösterilmiş ve elde edilen KOH değerlerine göre yaklaşık 1.6 piksellik mutlak doğruluğa ulaşılmıştır. Çalışmada kullanılan MS İHA'nın geometrik doğruluk performansının detaylı incelemesine [Sefercik and Nazar., 2023] ve [Sefercik et al., 2023] kaynaklarından erişim sağlayabilirsiniz.

**Tablo 5.4:** YKN ve BDN'lere ait koordinatlar ve hesaplanan konum doğruluğu.

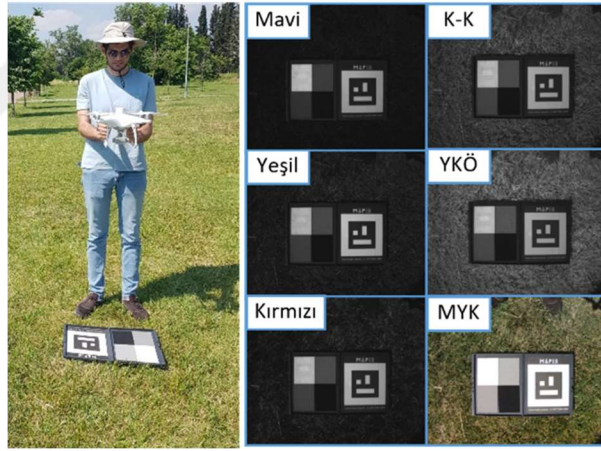
YKN/BDN	X (m)	Y (m)	Z (m)	KOH (m)	Ortalama KOH (m)	
					5 YKN	3 BDN
1	4519551.723	446080.035	46.353	<b>0.003</b>		
2	4519505.104	446258.296	45.961	0.106		
3	4519725.644	446390.207	47.367	0.031		
4	4519648.496	446186.873	46.795	0.013		
5	4519831.690	445925.637	47.363	<b>0.049</b>	0.016	0.099
6	4519692.207	445662.163	45.329	0.004		
7	4519570.695	445839.910	45.257	0.013		
8	4519816.588	445741.211	46.911	<b>0.116</b>		

Görüntü yöneltme işlemleri sonrasında multispektral algılayıcı (MS) ile kaydedilmiş görüntülerin radyometrik kalibrasyon işlemi gerçekleştirilmiştir. Radyometrik kalibrasyon, atmosferik etkilerin elimine edilerek piksel değerlerinden yüzey yansıtım değerlerine (reflektans) dönüşüm için öncül bir işlemdir [Smith and Milton, 1999], [Dehm, 2019]. Reflektans değeri ışık koşullarından bağımsızdır ve bu nedenle bilimsel çalışmalar için daha güvenilir bir kaynak oluşturmaktadır. İHA'nın görüntü alımında geçen süre ve değişken konumuna bağlı olarak farklılık gösteren atmosfer ve aydınlanma koşullarının spektral bilgi üzerinde oluşturduğu bozucu etkiler, kalibrasyon işleminin tekil görüntülerin her birine uygulanmasıyla ortadan kaldırılmakta ve görüntülerin bütününde standart yakalanmaktadır.

İHA üzerine monte edilmiş farklı spektral aralıklarda kayıt yapabilen algılayıcılar, radyometrik olarak kalibrasyonu tamamlanarak kullanıcılara sunulmaktadır ancak uçuş sırasında titreşim, rüzgar, sıcaklık vb. unsurların etkisiyle görüntü kaydı sırasında bozucu etkilere karşı hassastırlar [Hakala et al., 2018]. Bu etkileri ortadan kaldırmak için nokta bulutu üretimi öncesinde Agisoft Metahsape Pro yazılımında radyometrik kalibrasyon işlemi gerçekleştirilmiştir. Kalibrasyon işlemi için öncelikli olarak görüntünün radyans değerlerine ihtiyaç duyulmaktadır. İHA üzerinde konumlanmış MS algılayıcılar, her görüntü çekim noktasında mevcut bantlar için metaveri dosyasına sahip tekil görüntüler kaydetmektedir.

DJI Phantom 4 MS İHA cihazı görüntülere kaydettiği radyans değerinin yanı sıra üzerinde bulunan ışık sensörüyle de üzerinde toplanan ışığa ait irradyans değerini doğrudan tüm bantlardaki görüntülerin metaverisine eklemektedir [Wang, 2021]. Ancak kamera ve ışık sensörü olmak üzere her iki sensör karşılaştırıldığında, ışık sensörünün güneş ışınlarından doğrudan faydalanması ve algılayıcı sistemlerindeki farklılıklar sebebiyle farklı radyans değerlerine sahiptirler [Wang, 2021].


Agisoft Metashape Pro kalibrasyon işleminde ışık sensörünün dahil edilmesine dair kontrolü kullanıcıya sunmaktadır Şekil 5.12. Çeşitli kaynaklara göre kötü hava koşullarında aktif edilmesi gerekirken güneşli açık hava durumunda kullanılmaması önerilmiştir, ancak buna dair net bir ifade bulunmamaktadır [Daniels, 2023]. Önceki bölümlerde bahsedilen atmosferik ve dış etkilerin giderilmesi ve reflektans değerlerine ulaşmak amacıyla yersel ölçümlere ihtiyaç duyulmaktadır. Bu noktada MAPIR markalı reflektans panelinin, yaklaşık göğüs hizasından alınan 6-bantlı görüntü setinden kompozit (RGB) bant hariç tutularak, beş banttan faydalanılmıştır Şekil 5.10.



Şekil 5.10: Görüntü çekimi örneği ve altı farklı bantta MAPIR panel görüntüsü.

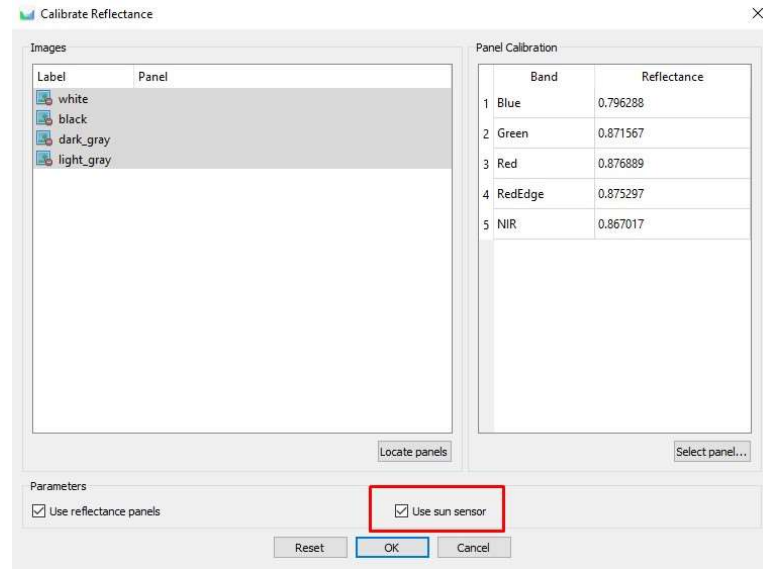
Reflektans paneli ile gerçekleştirilen kalibrasyon işleminde geliştiriciler tarafından önerilen iş akış süreci uygulanmıştır [Agisoft, 2022]. Literatürde sıkça yer alan ve çalışmalarımızda karşılaştığımız önemli bir problem de Agisoft gibi paket programların kullanıcılara sağladıkları çeşitli fotogrametrik ürünlerin, üretiminde faydalanılan algoritmalar hakkında bilgi paylaşılmamasıdır [Daniels, 2023].

Şekil 5.11’de siyah yüzey için örneği gösterildiği üzere tüm bantlar için panele ait dört farklı renk ayrı ayrı maskelenmiş ve görüntülerde sadece ilgili yüzeye ait alan içerisindeki pikseller kalibrasyon işlemine dahil edilmiştir. Maskeleye işlemde pencere boyutunun büyük olması daha fazla sayıda örnek pikselin algoritma tarafından değerlendirilmesini sağlamakta ve sonuçlarda pozitif etki göstermektedir [Assmann et al., 2018].



Şekil 5.11: MAPIR panel maskeleye işlemi: (a) öncesi, (b) sonrası.

Filtreleme işleminin ardından Agisoft yazılımında tüm bantlar için sunulan reflektans değerleri girilmiş ve ışık sensörü aktif biçimde kalibrasyon işlemi tamamlanmıştır Şekil 5.12.



Şekil 5.12: Agisoft ortamında MAPIR reflektans değerlerinin tanımlanması.


Nokta bulutu üretiminde radyometrik kalibrasyonu gerçekleştirilmiş görüntüler kullanılmıştır. Agisoft yazılımı nokta bulutu üretiminde SFM tabanlı çalışmaktadır, kullanıcı üretimde nokta bulutu kalitesi ve filtreleme olmak üzere iki adet parametrenin seçiminde kontrole sahiptir. Nokta bulutu kalitesi, üretimde kullanılacak olan görüntülerin çözünürlüğüne etki etmektedir. Bu parametre çok yüksek, yüksek, normal, düşük ve çok düşük olmak üzere beş farklı seçenekten oluşmaktadır. Çok yüksek seçeneği görüntünün orijinal hali (5.6 cm/piksel) ile çalışırken yüksek seçeneği 4 kat (11.2 cm/piksel), normal seçeneği 16 kat (22.4 cm/piksel), düşük seçeneği 64 kat (44.8 cm/piksel) ve çok düşük seçeneği 256 kat (89.6 cm/piksel) oranda çözünürlüğü düşürmektedir [Tinkham and Swayze, 2021]. Kalite parametresinin seçiminde; kullanılan donanımın özellikleri, çalışma alanı (yoğun vejetasyon, çıplak arazi vb.), üretimi hedeflenen fotogrametrik ürün (3B model, ortomozaik vb.) gibi değişkenler kullanıcı tarafından göz önünde bulundurulmalıdır. Çok yüksek kalite seçiminde yoğun bitki örtüsüne sahip alanlarda gürültü oluşumu sıklıkla karşılaşılan bir problemdir. Özellikle rüzgarlı hava koşullarında gerçekleştirilen veri alımlarında, yoğun bitki örtüsüne sahip alanlarda değişkenlik gösteren bitki konumları gürültülü noktaların oluşumunda son derece etkilidir [Dandois et al., 2015], [Frey et al., 2018]. Çalışma alanı içerisinde bina, yol, ormanlık alan gibi birçok sınıfın yer alması ve çevrelerinde oluşturdukları gölgeli alanlar gürültülü noktaların üretimine sebep olmaktadır. Bu sebeple daha detaylı, doğru geometrinin elde edilebilmesi için çeşitli kalite seçenekleri görsel olarak incelenmiş ve yüksek kalite seçeneği tercih edilmiştir. Minimum veri kaybı ve optimal düzeyde filtreleme işlemi için derinlik filtresi seçeneği aktif ve zayıf seçilmiştir. Kameranın tahmini pozisyonuna göre oluşturulan derinlik haritasını altlık olarak kullanan bu filtreleme yöntemi, belirli bindirme oranına sahip görüntüler arasındaki derinlik haritasını analiz ederek aykırı noktaların oluşumuna engel olmaktadır.

Nokta bulutu üretimi tamamlandıktan sonra, gerçek nesne konumlarından sapan düşük doğrulukta yanıtıcı nokta kümeleri manuel olarak filtrelenerek gürültülü nokta sınıfına atanmıştır. Manuel filtreleme işleminde, zemin altı noktalar ve özellikle yoğun orman alanlarının oluşturduğu gürültülü noktalar elimine edilmiştir. Bu şekilde fotogrametrik iş akışının devamında oluşabilecek doğruluk kayıplarının önüne geçilmiştir **Şekil 5.13**. Yoğun nokta bulutu, filtreleme öncesi 55.731.916 nokta bulundururken filtreleme işlemi sonrasında 55.581.436 noktayı içermektedir.




**Şekil 5.13:** Filtreleme işlemi uygulanmamış (a) ve uygulanmış (b) nokta bulutu.

Çalışma kapsamında, nokta bulutu üretimi aşamasının yanı sıra aynı İHA üzerinde yer alan farklı sensörlerle üretilen nokta bulutlarının, karşılaştırmalı analizi gerçekleştirilmiştir. Bu analizde görünür bölgede algılama yapan tek bantlı sensörle (RGB) üretilen nokta bulutu ve 5-bantlı algılama sistemi ile üretilen nokta bulutu görsel olarak analiz edilmiştir. **Şekil 5.14** incelendiğinde, görünür bölgede son derece benzer spektral özellik gösteren beyaz renkli çatı yapılarında, nokta bulutunun seyredildiği görülmektedir. Görüntü pikselleri arasındaki düşük kontrast detay noktalarının çıkarımını zorlaştırmış ve veri kaybıyla birlikte nokta bulutunda boş alanların oluşumuna sebep olmuştur. Kırmızı kenar ve yakın kızılötesi bantlarının yer aldığı 5-bantlı görüntülerin sağladığı zengin spektral bilgi içeriği ile üretilen nokta bulutunda, boş alanların boyutunda ciddi oranda azalma olduğu belirlenmiştir. NDYM üretiminde daha yoğun nokta içeriğine sahip 5-bantlı üretim sonucu kullanılmıştır.



**Şekil 5.14:** Ortofoto ve iki farklı kaynaktan üretilen nokta bulutu: (a) RGB kaynak, (b) 5-bantlı kaynak.


DYM üretimi, NDYM üretimi başlığı altında detaylı bir şekilde anlatılmıştır. DYM üretiminde enterpolasyon yöntemi ve parametrelerinin seçiminin mümkün olmaması sebebiyle Agisoft programından elde edilen DYM yalnızca ortomozaik üretimi için kullanılmıştır **Şekil 5.15**.



**Şekil 5.15:** DYM sonucu.

DYM üretiminin ardından, yükseklik bilgisine sahip her bir piksel görüntülerde yer alan spektral karşılıkları ile ilişkilendirilmiş ve ortaya çıkan ortofotoların mozaiklenmesi işlemiyle fotogrametrik iş akışının nihai ürünü olan ortomozaik üretimi tamamlanmıştır. **Şekil 5.16-17**'de yer alan ortomozaikler, yüksek konum doğruluğu hedefiyle yaklaşık 5.5 cm mekansal çözünürlük değeri ile üretilmiş ve beş farklı bant bilgisini içermektedir. **Şekil 5.16** radyometrik kalibrasyonu gerçekleştirilmemiş hava fotoğrafları ile üretilmiştir ve ortomozaik üzerindeki farklı bölgelerdeki spektral bilgilerin hatalı olduğu net bir şekilde görülebilmektedir. **Şekil 17** ise radyometrik kalibrasyon uygulanmış hava fotoğraflarından üretilen ortomozaik veriyi göstermektedir ve nesnelere temsil eden spektral özelliklerin daha anlamlı ve doğru olduğu, kalibrasyon işleminin başarılı sonuçlar ürettiği belirlenmiştir.

Sonrasında raster formatlı NDYM verisinde yer alan eş koordinatlı örtüşen pikseller arasında maksimum uyumun yakalanabilmesi amacıyla, ortomozaik 10 cm değerine yeniden örneklenecek sınıflandırma sürecine dahil edilmiştir.



Şekil 5.16: Radyometrik kalibrasyon uygulanmamış 5-bantlı ortomozaik.



Şekil 5.17: Radyometrik kalibrasyon uygulanmış 5-bantlı ortomozaik.

### 5.3. Normalize Dijital Yüzey Modeli (NDYM) Üretimi

NDYM, herhangi bir hedef alanda, doğal ve insan eliyle inşaa edilmiş tüm objelerin nadir bakış geometrisinde görünür yüzeylerinin X, Y planimetrik konum koordinatları ve Z yükseklik değerleri ile 3B kartoğrafik tasvirini gerçekleştiren DYM ile aynı alanda yalnızca çıplak yeryüzü topoğrafyasının 3B kartoğrafik tasvirini sunan dijital

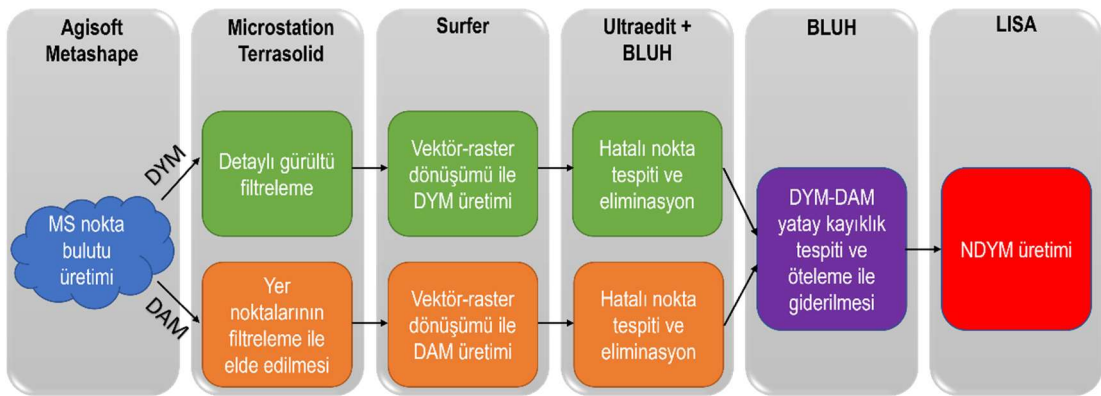
arazi/yükseklik modellerinin farkından elde edilen 3B üründür (Denklem 5.1). Bu ürün sayesinde, yeryüzü topoğrafyası üzerindeki tüm objelerin taç yüzey kotlarından çıplak topoğrafya kotu çıkarılması temelinde, 3B yalın tasvirleri sağlanmaktadır. Bina yükseklikleri, orman tekil ağaç ve meşcere yükseklikleri gibi bilgi sistemleri açısından çok değerli envanter bilgileri NDYM üretimi yoluyla elde edilmektedir.

$$NDYM = DYM - DAM \quad (5.1)$$

NDYM üretimi ve kullanımı özellikle hava kaynaklı lazer tarama (ALS/Lidar) teknolojisinin ortaya çıktığı dönemden günümüze hızlı bir ivme ile artış göstermiştir. ALS, yoğun ve çok dönüşlü sinyal atımına bağlı bitki penetrasyon yeteneği sayesinde kamera donanımlı optik sistemlerin aksine bitki altı yeryüzü topoğrafyasının modellenebilmesine olanak vermekte ve sağladığı yoğun nokta bulutları sayesinde bitki kaplı alanlarda yüksek kalitede NDYM üretimini olası kılmaktadır. ALS tekniği ile üretilen yüksek çözünürlükte ve kalitede NDYM'ler özellikle orman ve tarım envanter çalışmalarında bitkilere ait tür, boy, fenolojik evre, eğiklik, gövde çapı gibi fiziksel parametrelerin tespitinde yoğun şekilde kullanılmaktadır [**Lindberg and Hollaus, 2012**], [**Szostak et al., 2014**]. ALS teknolojisinden elde edilen yoğun nokta bulutları ile kullanımı yaygınlaşan NDYM, haritacılık alanında da giderek daha fazla kullanılmaya başlanmıştır. Özellikle, biçimsel (shape) ve spektral heterojenlik temelinde iki boyutlu prensipte gerçekleştirilen obje sınıflandırma çalışmalarında obje yüksekliğine bağlı üçüncü boyut bilgisini sağlaması, sınıflandırma kalitesi anlamında NDYM ürününü çok değerli kılmaktadır. Bu doğrultuda, haritacılık disiplininde hem hava hem de uzay kaynaklı uzaktan algılama verileri ile gerçekleştirilen obje sınıflandırma çalışmalarında NDYM kullanımı büyük önem kazanmıştır [**Sefercik et al., 2014**], [**Sefercik and Atesoglu, 2017**], [**Sefercik et al., 2018**], [**Huo et al., 2018**], [**Aval et al., 2019**].

ALS teknolojisinden elde edilen yoğun nokta bulutlarından harita ürünlerinin üretiminde elde edilen başarı, nokta bulutu prensibinin fotogrametri teknolojisine entegrasyonunu beraberinde getirmiştir. Özellikle, 2013 yılında Çin menşeli DJI firmasının ticari amaçlı ilk sivil İHA olan Phantom I'i kullanıma sunması ile devinime giren optik İHA teknolojisi ve bu teknolojiden elde edilen yüksek çözünürlüklü hava

fotoğraflarının işlenmesi için kullanılan ticari paket yazılımlar fotogrametride nokta bulutu kavramının giderek yaygınlaşmasına zemin hazırlamıştır. Alçak irtifalarda uçuş yapabilme avantajı sayesinde İHA teknolojisi ile ALS'den elde edilen çözünürlük seviyelerinde yoğun nokta bulutları rahatlıkla elde edilebilmektedir. Bu durum, yüksek kalitede NDYM üretiminin İHA verileri temelinde gerçekleştirilebilmesinin önünü açmıştır. ALS gibi pahalı donanımlara ihtiyaç duymayan ve istenilen zamansal periyotlarda uçuşa ve veri alımına olanak veren İHA teknolojisi NDYM üretimine dayalı bitki gelişim ve bina yapılaşmalarının izlenmesi temelindeki projelerde ALS'ye nazaran çok daha yoğun tercih edilmeye başlanmıştır. Ancak, her teknolojinin sağladığı avantajlar yanında dezavantajlarının da bulunduğu unutulmaması gereken bir gerçekliktir. Çalışma alanının çok geniş olması durumunda (il bazındaki işlemler vb.) İHA'lar batarya ömürleri, sensör karakteristikleri ve resmi uçuş yükseklik sınırlamaları nedenleriyle ALS teknolojisine alternatif oluşturamazlar. Ayrıca, kamera donanımlı İHA'lar ALS teknolojisindeki gibi bitki penetrasyon yeteneğine sahip olmamaları nedeniyle bitki kaplı alanlarda çıplak yeryüzü topoğrafyasının modellenmesi konusunda veri eksikliğine bağlı potansiyel kaybı yaşamakta ve bitki altı topoğrafyada 3B modellerin üretimi zorlu bir süreç olarak karşımıza çıkmaktadır. Bu durum, NDYM üretimi için harcanan zamanın da uzamasına yol açmaktadır. Bu çalışmada, NDYM üretimi için gerçekleştirilen işlemlere ilişkin akış diyagramı **Şekil 5.18**'de sunulmuştur.



**Şekil 5.18:** NDYM üretimi iş akış diyagramı.

Agisoft Metashape yazılımında geometrik ve radyometrik düzetmelerin uygulanması ile üretilen MS yoğun nokta bulutu bu yazılımdaki filtrelemelerin yüksek kalitede DYM ve DAM üretimi için yetersiz kalması nedeniyle Microstation yazılımına


aktarılmış ve detaylı filtrelemeler Terrasolid bileşenlerinden Terrascan modülü kullanılarak tamamlanmıştır. DYM üretiminde kullanılacak yoğun nokta bulutunda detaylı gürültü filtrelemesi fence (pencere) metodu ile manuel olarak gerçekleştirilirken DAM üretimi için gerekli olan yer noktalarının elde edilmesinde otomatik filtre uygulanmıştır. Çalışma alanında yer alan objelerin ve kullanılan İHA'nın özellikleri göz önünde bulundurularak iteratif deneme ve kontroller sonucunda optimal otomatik filtre parametreleri belirlenmiştir **Tablo 5.5**.

**Tablo 5.5:** Yer noktalarının elde edilmesinde kullanılan otomatik filtreleme parametreleri.

Maks. bina genişliği (m)	Arazi açısı (°)	İterasyon açısı (°)	İterasyon mesafesi (m)	Kenar <5m olduğunda iterasyon açısının azaltılması	Kenar < 2m olduğunda üçgenlemenin durdurulması	Yer noktası sayısı	Yer noktası yükseklik aralığı (m)
60	50	4	1.50	+	-	831426	39.31-53.78

Uygulanan filtreleme işlemlerinin ardından elde edilen DYM ve DAM nokta bulutları Surfer yazılımına aktarılmış ve enterpolasyon temelinde vektör-raster dönüşümü gerçekleştirilmiştir. Enterpolasyon işlemi düzenli grid yapıda 3B model üretimi için mecburi bir uygulama olmakla beraber üretilen modelin kalitesini doğrudan etkilemektedir. Enterpolasyon, 3B modelin özellikle yükseklik doğruluğunu düşürücü bir uygulama olması nedeniyle seçilen yöntem model kalitesi üzerinde doğrudan etkilidir. Vektör yapıdaki yoğun nokta bulutu verisi raster DYM formuna dönüştürülürken aynı piksel içine düşey ekseninde çok sayıda nokta dahil olmakta ve bu durum modellemede hangi noktaların kullanılacağı konusunda problem ortaya çıkarmaktadır. Bu ve benzeri konularda her enterpolasyon yöntemi farklı yaklaşımlar kullanmaktadır. Bu çalışmada, DYM üretiminde Data Metrics (DM) enterpolasyon yöntemi tercih edilmiştir. Bu tercihin nedeni, DM yönteminin her piksel için maksimum yükseklikli nokta kullanımına olanak vermesidir. DAM üretiminde ise enterpolasyon yöntemi yalnızca yer noktalarının kullanımı nedeniyle DYM üretimindeki kadar problematik değildir ve triangülasyon (üçgenleme), lineer, bilinear, en yakın komşuluk vb. klasik yöntemler rahatlıkla kullanılabilir. Bu çalışmada, DAM üretimi için triangülasyon enterpolasyon yöntemi tercih edilmiştir. Vektör verilerden 3B katı model üretiminde bir diğer önemli parametre enterpolasyon pencere


boyutudur. Bu boyut, bir pikselin deęer tayininde ne kadar mesafedeki noktaların enterpolasyon işlemine dahil edileceğini tanımlar. Boşluklu yapının fazla olduğu vektör verilerde bu deęer yeterli sayıda noktanın kullanılabilmesi için daha büyük uygulanmalıdır [Sefercik et al., 2018]. Bu noktadan hareketle, çalışmada, DYM üretiminde nokta sayısı yoğunluğu nedeniyle 5 m enterpolasyon pencere genişliği kullanılırken DAM üretiminde nokta sayısındaki sınırlılık göz önünde bulundurularak 10 m pencere genişliği uygulanmıştır. Üretilen DYM ve DAM'lara ait düzenli ASCII grid dosyalar üzerindeki hatalı noktalar Ultraedit ve BLUH (Bundle Block Adjustment Leibniz University Hannover) yazılımları kullanılarak tespit edilip elimine edilmiştir. Belirtilen bu önemli parametreler dikkate alınarak 0.1 m grid aralığında üretilen ve hatalı noktaları elimine edilen DYM ve DAM Şekil 5.19'da yer almaktadır.



Şekil 5.19: Üretilen DYM (üst) ve DAM (alt).

Yüksek kalitede NDYM üretimi için diferansiyeli alınacak DYM ve DAM'ın yatayda tam olarak örtüşmeleri büyük önem taşımaktadır. Aksi halde, yatay konum kayıklığına bağlı olarak NDYM yükseklik tasvirleri hatalı ve yanıltıcı olacaktır. Genel olarak, farklı geometrilerden elde edilen uydu ve hava verilerinden üretilen modellerin beraber işleme sokulması ya da yakın algılama geometrilerinden farklı sensörlerce kaydedilen verilerin beraber değerlendirilmesi durumlarında yatay konum kayıklıkları rahatlıkla birkaç piksel düzeyine ulaşabilmektedir. Bu çalışmada, modellerin yatayda %100 örtüşümünün sağlanması için aralarındaki yatay konum kayıklıkları BLUH yazılımı ile tespit edilmiştir. Yatay konum kayıklıklarının, DYM ve DAM'ın aynı sensöre ait verilerden üretilmiş olmasının avantajı ve doğru şekilde uygulanan enterpolasyon parametreleri sayesinde ihmal edilebilir boyutta (<0.1 piksel) olduğu belirlenmiştir.

Yukarıda bahsedilen tüm konular dikkate alınarak LISA yazılımında üretilen 0.1 m grid aralıklı NDYM Şekil 5.20'de yer almaktadır. NDYM, şekilden de anlaşılacağı üzere çalışma alanındaki doğal ve insan yapısı tüm objelerin yalın tasvirini yüksek çözünürlükte başarılı şekilde yansıtmaktadır.

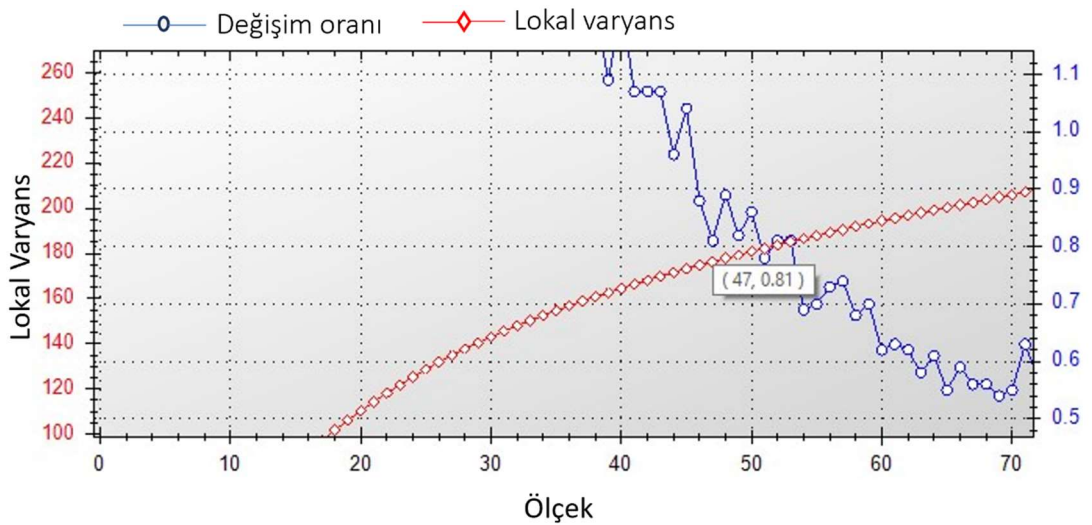


Şekil 5.20: Üretilen 0.1 m grid aralıklı NDYM.

## 5.4. Görüntü Segmentasyonu

OTGA yaklaşımında segmentasyon, dijital görüntünün içerdiği homojen özelliklerin (radyometrik ve geometrik) değerlendirilmesi ve benzer özelliklere sahip piksellerin gruplandırılması işlemidir [Modica et al., 2021]. Tez çalışması kapsamında eCognition Developer yazılımı kullanılarak çoklu çözünürlük segmentasyon yöntemi uygulanmıştır. Bu yöntem için ideal parametrelerin belirlenmesinde literatürde yaygın olarak kullanılan ESP-2 aracı ve görsel analizlerden faydalanılmıştır. Biçim ve bütünlük parametrelerinin belirlenmesinde ampirik yöntemler kullanılmış ve en uygun değer olarak sırasıyla 0.6 ve 0.4 değerlerine ulaşılmıştır.


Hava fotoğrafları ile üretimi tamamlanan 5 bantlı ortomozaik verisine, yüksek doğrulukta üretilen raster formatlı NDYM ek bant olarak entegre edilmiştir. Her iki veri seti için optimum parametrelerin seçimi ve segmentasyon işlemi uygulanmış, sonuç çıktıları ayrıca değerlendirilmiştir. Ölçek parametresinin belirlenmesinde ESP-2 aracı eCognition yazılımında ek araç olarak dahil edilerek uygulanmıştır. Şekil 5.21, 5 bant ortomozaik için ölçek parametresinin belirlenmesinde kullanılan ESP-2 aracının sonuç grafiğini göstermektedir. Bu grafik lokal varyans değerlerini ve değişim oranını ölçek değerine bağlı olarak ifade etmektedir ve bu orandaki ilk ani değişim değeri, ölçek için optimum değer olarak kabul edilmektedir. Çalışma kapsamında ESP-2 algoritması aracılığıyla 5 bantlı ortomozaik için ölçek parametresi 47 olarak belirlenmiştir.



Şekil 5.21: 5 bant ortomozaik için ölçek parametresinin belirlenmesinde ESP-2 grafiği.

5 bant ortomozaik için tüm bantlar eşit ağırlıklı alınarak segmentasyon işlemine dahil edilirken 6 bant ortomozaik için NDYM verisinin ağırlık değeri 0.5 olarak seçilmiştir. Bu değerin daha düşük ağırlıklı seçimindeki temel hedef, farklı yazılımlar ve enterpolasyon süreci ile üretilen NDYM verisinin ortomozaik altlık ile maksimum uyumunun yakalanabilmesidir. Bunun yanı sıra, NDYM ağırlığı arttıkça spektral bilginin önemi azalmakta ve eğimli bölgeler için yükseklik değerindeki değişime bağlı olarak gereksiz segment oluşumu söz konusu olmaktadır. Bu çıkarımlara dayanarak, yükseklik bilgisinin dahil edildiği uygulamalarda ağırlık değerlerinin kullanıcı kontrolü ile belirlenmesi son derece önem arz etmektedir.

NDYM bantı, sürekliliğini koruyan nesnelere ait görüntü objeleri için eş değerlerde yükseklik bilgisi sağladığından 5 bant ortomozaikte belirlenen ölçek parametresi değerinin arttırılmasıyla homojen yapının korunarak daha büyük boyutlu segmentlerin oluşturulabileceği öngörülmüştür. Bu fikirden yola çıkılarak 6 bant ortomozaik için aynı sınıfa ait görüntü objelerinin belirlenmesinde eşik değeri daha yüksek tutulmuş ve ölçek parametresi 60 olarak denenmiştir. Üretilen görüntü objeleri incelendiğinde ise son derece başarılı sonuçlar elde edilmiştir. **Şekil 5.22**'de bina yapılarını tasvir eden segmentlerdeki değişime ait örnekler gösterilmektedir. Eş kotlu çatı alanlarının NDYM verisi ile daha bütüncül ve büyük boyutlu segmentler ile temsil edilebildiği görülmüştür.




**Şekil 5.22:** NDYM bantının segmentasyon işlemi üzerindeki etkisi.

**Şekil 5.23'**te 5 ve 6 bantlı ortomozaik için gerçekleştirilen segmentasyon sonucu görülmektedir. Yükseklik bilgisinin bulunmadığı 5 bantlı veri için çoklu çözünürlük segmentasyon işlemi 304.589 görüntü objesi oluşturulurken, 6 bantlı veri için 151.769 görüntü objesi üretmiştir. Görüntü objelerinin sayısındaki farklılığın temel nedenleri, özellikle eş kotlu bina çatı yüzeyleri, ulaşım yolu sınıflarının görüntü objelerinin daha büyük boyutlu üretimi ve **Tablo 5.6'**da özetlenen ölçek parametresi değerinin 60 olarak seçilmesidir.

**Tablo 5.6:** İki farklı veri seti için belirlenen segmentasyon parametreleri ve üretilen görüntü objesi sayısı.

Segmentasyon parametreleri	Görüntü Objeleri	
	5 bant	*6 bant
Ölçek	47 – *60	
Biçim	0.6 – *0.6	304.589 151.769
Bütünlük	0.4 – *0.4	



**Şekil 5.23:** 5-bant (a) ve 6-bant (b) veri setleri için segmentasyon sonucu.

Her bir görüntü objesi için metodoloji bölümünde belirtilen bant özelliklerine dayalı 12 spektral, bu bantların oranlanması yoluyla türetilen 40 indis, GLCM dayalı sekiz doku, biçimsel özelliklere dayalı sekiz geometri ve NDYM özelliği tanımlanmış ve poligon formatında dışarıya aktarılmıştır. Görüntü özelliklerine dayalı olarak üretilen çeşitli özellikler gruplandırılmış ve bunların kombinasyonları ile dört farklı alt veri kümesi oluşturulmuştur **Tablo 5.7**. Veri kümelerinin oluşturulmasındaki temel hedef, özellik gruplarının sınıflandırma üzerinde etkilerinin bağımsız şekilde değerlendirilebilmesi ve bu veri kümelerinin farklı sınıflandırıcılar için sağladığı performans artışının anlaşılabilir hale getirilmesidir. Veri kümeleri 5 ve 6 bantlı ortomozaiklerin segmentasyonu sonucu üretilen görüntü objeleri için ayrı ayrı

tasarlanmış ve uygulanmıştır. V1 veri seti yalnızca bant bilgilerinden üretilen spektral ve indis özelliklerinden oluşurken V2 veri seti bu bilgilere ek olarak doku ve geometri özelliklerini de içermektedir. V3 veri seti ise V2 veri setine yükseklik bilgisini içeren NDYM'nin de özellik olarak dahil edilmesiyle oluşturulmuştur. 5 bantlı ortomozaik segmentasyon sürecinde NDYM bandını içermezken, görüntü objeleriyle sınırlandırılmış alan için NDYM üzerinden ortalama yükseklik bilgisi çıkarımı gerçekleştirilmiş ve ek özellik olarak V3 veri setine dahil edilmiştir.

**Tablo 5.7:** Çalışma kapsamında kullanılan veri setleri.

Veri setleri	Özellikler
V1	Spektral + İndis
V2	Spektral + İndis + Doku + Geometri
V3	Spektral + İndis + Doku + Geometri + NDYM
V4	V3 + özyinelemeli özellik seçimi

## 5.5. Eğitim Verilerinin Oluşturulması

Sınıflandırma çalışması için kullanılan makine öğrenmesi modellerinin eğitimi amacıyla her sınıfa ait örnek toplama işlemi gerçekleştirilmiştir. Eğitim verisinin üretimi kullanıcı kontrolü ile gerçekleştirilmektedir ve sınıflandırma sonucunu doğrudan etkilediğinden son derece önemli bir işlem adıdır [Ma et al., 2015]. Uçuş öncesi gerçekleştirilen keşif çalışmasında çalışma alanında bulunan sınıflar değerlendirilmiş ve sonrasındaki etiketleme işlemi için bilgi toplanmıştır. Sınıflara ait örnek görüntü objeleri etiketlenirken, en doğru sınıf temsiline sahip objelerin seçimi dikkate alınmıştır. Ağırlıklı olarak içerisinde heterojen sınıf bilgisi bulundurmayan homojen yapılı objeler tercih edilmiştir ve ArcMAP yazılımında etiketlenmiştir. Şekil 5.24'te 5-bant (a) ve 6-bant (b) ortomozaik ile gerçekleştirilen segmentasyon sonuçları için belirlenen örnek veriler gösterilmektedir.



**Şekil 5.24:** 5-bant (a) ve 6-bant (b) segmentasyon sonuçları için tüm sınıflara ait örnek veriler.

Her iki veri seti için toplanan örnek sayısı sınıf bazlı olarak **Tablo 5.8'** de sunulmuştur. Segmentasyon başlığı altında segment sayılarındaki farklılıktan bahsedilmiştir ve buna bağlı olarak toplanan eğitim örneklerinin sayıları farklı veri setleri için değişkenlik göstermiştir ancak sınıf etiketi tanımlanırken her iki segment grubu için aynı özellikleri içeren segmentlerin seçimine önem gösterilmiştir. Toplanan örneklerin %80'i eğitim amaçlı %20'lik kısmı ise model doğruluğunun kontrolü için kullanılmıştır.

**Tablo 5.8:** Eğitim verilerinin sınıf bazlı dağılımları.

<b>Sınıf</b>	<b>5 Bant</b>	<b>6 Bant</b>
Kırmızı Çatı	269	164
Beton Çatı	295	185
Yol	582	398
Su	330	248
Gölge	76	58
Seyrek Bitki Örtüsü	125	71
Yoğun Bitki Örtüsü	476	300
Bisiklet Yolu	244	165
Toprak	501	321
Geniş Yapraklı Ağaç	466	413
İğne Yapraklı Ağaç	643	585
Toplam	4007	2908

## 5.6. AÖ/AK Sınıflandırma

Tez kapsamında AÖ/AK sınıflandırma çalışmalarında yaygın olarak kullanılan RF, SVM, XGBoost makine öğrenmesi algoritmalarının tasarlanan veri setleri için performansları karşılaştırmalı olarak test edilmiştir. Her bir sınıflandırıcı toplanan örnekler yardımıyla eğitilmiş ve 21 farklı tematik haritanın üretimi gerçekleştirilmiştir. V4 veri seti sadece 5 bantlı ortomozaik üzerinde uygulanmış ve elde edilen çıkarımlar neticesinde 6 bantlı ortomozaik üzerinde uygulanmasına gerek görülmemiştir. **Tablo 5.9'** da veri setleri ve sınıflandırıcılara ait özet bilgiler verilmiştir.

**Tablo 5.9:** Veri setleri ve sınıflandırıcılara göre üretilen tematik haritalar.

<b>Veri setleri</b>	<b>5 Bant / 6 Bant</b>		
	<b>RF</b>	<b>SVM</b>	<b>XGBoost</b>
V1	✓ / ✓	✓ / ✓	✓ / ✓
V2	✓ / ✓	✓ / ✓	✓ / ✓
V3	✓ / ✓	✓ / ✓	✓ / ✓
V4	✓ / X	✓ / X	✓ / X

Sınıflandırma algoritmalarının, eğitim için kullanılan veri setine bağlı kalmadan yüksek performans gösterebilmeleri amacıyla en uygun hiper parametrelerin belirlenmesi gerekmektedir. Hiper parametrelerin optimizasyonu için eğitim örneklerinden oluşan veri setini eş parçalara bölerek, belirlenen aralık ve artış miktarına bağlı olarak model performansını analiz eden GridSearchCV yöntemi

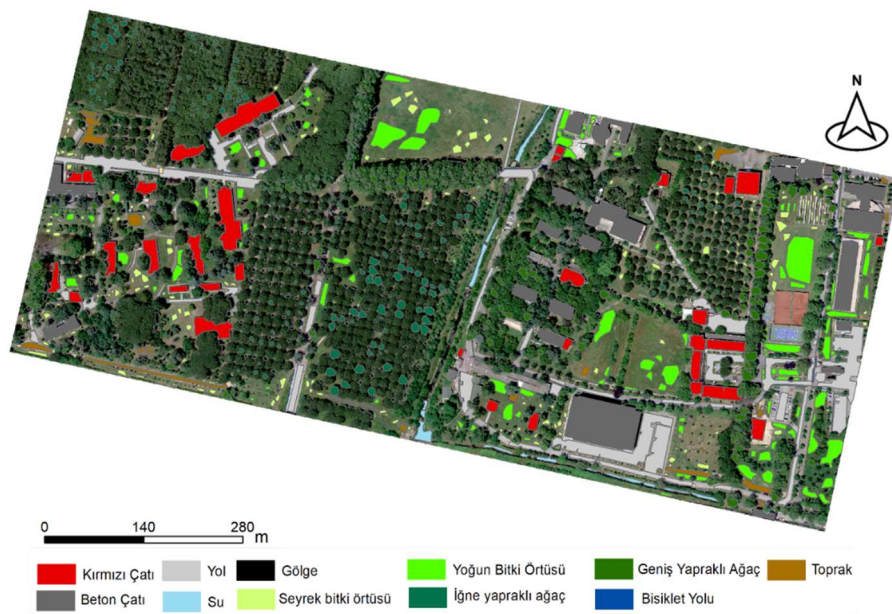
kullanılmıştır. Bu yöntem model performansını değerlendirmek amacıyla her bir parametre kombinasyonu için k-kat çapraz doğrulama işlemi gerçekleştirilmektedir.

K değeri belirli eşik değerinin üstünde uygulandığı durumlarda eğitim verisinin bölünme oranı artmakta ve hiper parametrelerin optimizasyon performansı için negatif yönlü etki oluşturmaktadır. Yüksek bölünme oranı ile eğitim verisinin alt gruplarında yer alan örnekler çalışma genelini iyi temsil edemeyecek konuma gelmekte ve parametre kestiriminde istenen sonuçlara ulaşamamaktadır. Yüksek çözünürlüklü ortomozaik verisinin, sahip olduğu veri hacmi ve mevcut donanım kapasitesi dikkate alınarak k değişkeni için beş değeri en uygun değer olarak belirlenmiş ve 5-kat çapraz doğrulama işlemi uygulanmıştır. Eğitim setinden oluşan girdi verisi beş alt gruba bölünerek sınıflandırıcılar için temel parametre setleri belirlenen aralıklar arasında tüm gruplar için test edilmiştir. Bu yaklaşım her bir makine öğrenme algoritması için uygulanmış ve optimal değerlerin bulunup veri setinin tamamı üzerinde denenmesi hedeflenmiştir. **Tablo 5.10** farklı veri setleri ve algoritmalara göre GridSearchCV yöntemi ile belirlenen parametre değerlerini göstermektedir. Özellik sayısı olarak isimlendirilen bölüm veri setlerinin (V1, V2, V3, V4) içerdiği özelliklerin toplam sayısını ifade etmektedir. Her bir algoritmada kullanılan parametrelere ait bilgiler ilgili başlıklar altında detaylı bir şekilde açıklanmıştır. Tablo geneli incelendiğinde doku ve geometrik özelliklerin V1 veri setine eklenmesiyle oluşturulan V2 veri seti için sınıf ayırımında RF algoritmasının çok sayıda ağaç içeren daha kompleks bir yapıya ihtiyaç duyduğu görülmüştür. Bunun yanı sıra V2 veri seti için SVM ve XGBoost algoritmalarının model yapısı nispeten daha sade bir yapıya bürünmüştür. NDYM verisinin de dahil olmasıyla birlikte (V3) tüm algoritmalar için sınıf ayırımı kolaylaşmış ve model yapısı daha basit bir hal almıştır.

**Tablo 5.10:** GridSearchCV yöntemi ile belirlenen parametre değerleri.

Sınıflandırıcı	Parametreler	V1	V2	V3	V4
RF	Maksimum ağaç derinliği	20	15	10	15
	Min Samples Leaf	1	1	1	1
	Min samples split	2	2	5	2
	ntree	130	350	40	40
	Özellik sayısı	52	68	69	53
SVM	C	79	4	4	4
	Kernel	Lineer	Lineer	Lineer	Lineer
	Gamma	0.0001	0.1	0.1	0.1
	Özellik sayısı	52	68	69	66
XGBoost	Colsample_bytree	0.8	0.6	0.6	0.6
	Gamma	0.5	0.5	0.5	0.5
	Maks. derinlik	0.1	0.1	0.1	0.1
	Min child weight	6	7	7	7
	n_estimator	5	5	5	5
	Özellik alt örnekleme	180	180	180	180
	Özellik sayısı	52	68	69	57

Şekil 5.25 üretilen tematik haritaların doğruluk değerlendirmesi için ihtiyaç duyulan referans veriyi temsil etmektedir. Referans verinin üretiminde, yüksek çözünürlüklü ortomozaik altlık olarak kullanılmış ve sınıf tanımlamaları arazi keşfiyle elde edilen bilgiler ışığında görsel yorumlamalar ile gerçekleştirilmiştir. Her bir sınıfa ait referanslar, ArcGIS ortamında raster görüntü üzerinden vektörleştirme işlemi ile tanımlanan poligonların, sınıf etiketinin tanımlanmasıyla gerçekleştirilmiştir.



**Şekil 5.25:** Doğruluk değerlendirmesi amacıyla üretilen referans veriler.

Doğruluk değerlendirmesinde tematik harita sonuçları için yaygın olarak kullanılan, F1 skor ve genel doğruluk metrikleri kullanılmıştır. Bu metriklerin üretimi, QGIS ortamında referans veri ve tematik haritanın örtüşen piksellerine dayalı olarak üretilen hata matrisi ile gerçekleştirilmiştir. Hata matrisleri, kullanıcı doğruluğu, üretici doğruluğu ve genel doğruluk metriklerinin hesabında kullanılmaktadır. Sınıflandırma sonucunun doğruluğunu yansıttasının yanı sıra sınıflar arası etkileşimi göstermekte ve yanlış sınıflandırılan alanları net bir şekilde ortaya koymaktadır.

### 5.6.1. Rastgele Orman

Tez kapsamında AÖ/AK sınıflarının belirlenmesinde RF yöntemi uygulanmıştır. Özyinelemeli özellik seçimi algoritmasının uygulanmasıyla **Tablo 5.11**'de belirtilen özelliklerin sınıflandırma üzerinde etkisinin çok düşük olduğu ya da etkisiz olduğu belirlenmiştir. Çalışma kapsamında tanımlanan tüm özelliklerin mevcut olduğu V3 veri setinden, belirlenen bu özellikler çıkarılarak V4 veri seti tasarlanmış ve sınıflandırma performansı diğer veri setleri (V1, V2, V3) ile karşılaştırmalı biçimde analiz edilmiştir.

**Tablo 5.11:** RF için özyinelemeli özellik seçimi yöntemi ile belirlenen etkisiz özellikler.

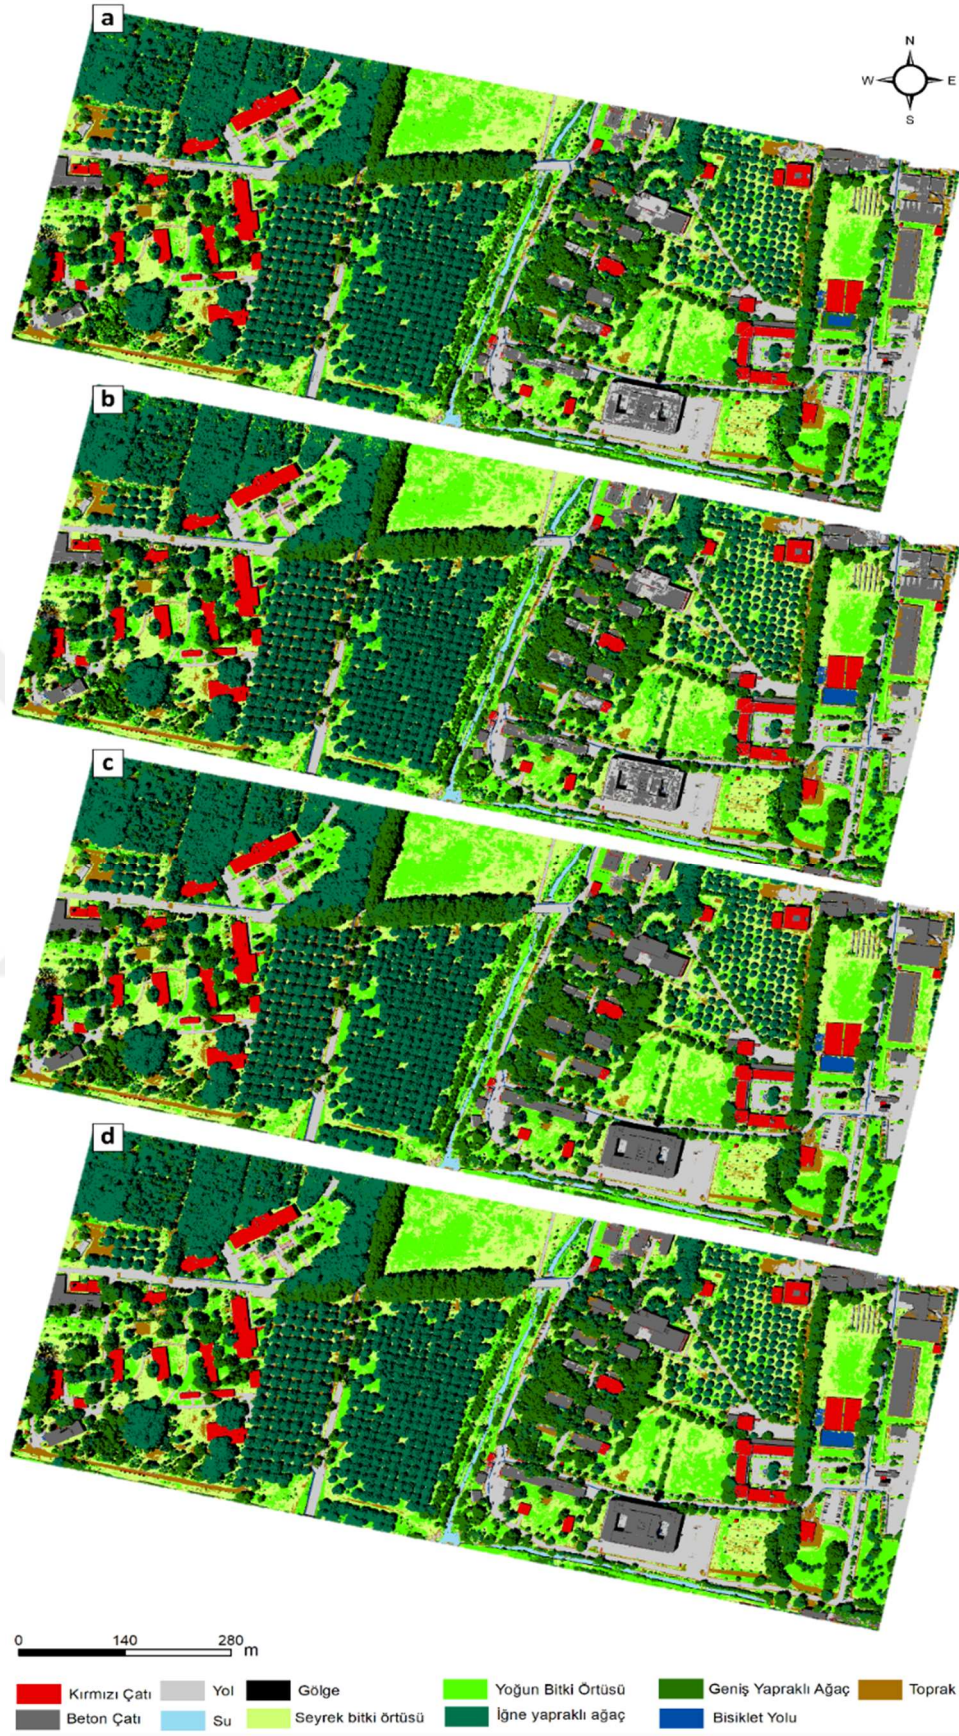
Spektral	İndis	Doku	Geometri
SS. Kırmızı	MRESR	Açısal ikinci moment	Uzunluk/genişlik
SS. Mavi	MSAVI2	Ortalama	Alan
Maksimum fark		Entropi	Bütünlük
			Sınır uzunluğu
			Asimetri
			Yoğunluk
			Dikdörtgen
			Ana Doğrultu

Özellik seçiminde toplam 69 adet bileşen değerlendirilmiş ve üç spektral, iki indis, üç doku ve geometrik özelliklerin tamamının sınıflandırma üzerinde ihmal edilebilir boyutta etkisinin olduğu belirlenmiştir. Görüntü objelerinin, ilişkili oldukları sınıflara dair geometrik özellikleri tam anlamıyla temsil edememesi ya da tüm sınıflardaki

nesnelerin benzer geometrik özelliklere sahip olması, bu sebeple biçimsel özelliklerin sınıf ayrımında fayda sağlamaması gibi varsayımların neticesinde, tüm geometrik özelliklerin etkisiz bileşen olarak değerlendirildiği düşünülmektedir.

**Şekil 5.26**, 5-bantlı ortomozaik kaynağından oluşturulan dört farklı veri seti için RF algoritması sonucunda üretilen tematik haritaları göstermektedir. V1 ve V2 veri seti ile üretilen tematik harita sonuçları incelendiğinde, sınıflandırma sonuçları arasında ciddi farklılıkların olmadığı ve tüm yapıların benzer sınıf etiketleri ile temsil edildiği görülmektedir.

V3 ve V4 veri setleriyle üretilen tematik haritalar değerlendirildiğinde ise yükseklik bilgisinin mevcut oluşunun özellikle beton çatı ve yol gibi yüksek spektral benzerliğe sahip su geçirimsiz alanların sınıf ayrımında son derece etkili olduğu görülmektedir. Kırmızı çatılı bina sınıfı özelinde yapılan değerlendirmelerde, tüm veri setlerinde yüksek başarı ile çıkarılabildiği görülmektedir ve bu sonuç spektral bilgi ve indislerden oluşan özellik setinin bu sınıfın tespitinde yeterli olduğu çıkarımına varılmasını sağlamıştır.




Şekil 5.26: 5-bantlı ortomozaik veri ve RF algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c), V4 (d) veri setleri için üretilen tematik haritalar.

Şekil 5.27’de 6-bantlı ortomozaikten üretilen üç farklı veri seti ve RF yönteminin uygulandığı tematik harita sonuçları görülmektedir. Görsel yorumlamalarda, 5-bantlı ortomozaik kullanılarak üretilen tematik haritalarla, benzer sonuçların ortaya koyulduğu gözlemlenmektedir.



Şekil 5.27: 6 bantlı ortomozaik veri ve RF algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.


**Şekil 5.28** iki farklı bina yapısına ait V1, V2, V3 veri setleri ve RF yöntemi ile gerçekleştirilen sınıflandırma sonucunda üretilen tematik haritaları ve referans görseli göstermektedir. 6-bantlı ortomozaik kullanılarak gerçekleştirilen sınıflandırmada, 5-bantlı görüntüye kıyasla gözlemlenen çok küçük görsel farklılıklar, iki görüntü arasındaki oldukça yakın performansı göstermektedir. V3 veri setine ait sonuçların analizi, V1 ve V2 veri setlerinde yol sınıfı ile karışan beton çatı sınıfının başarılı bir şekilde tasvir edildiğini ve yüksek spektral benzerlikten kaynaklanan yanlış sınıflandırma sorununun giderildiği görülmektedir. Her iki referans obje için de benzer sonuçlar elde edilmiş ve bu durum sonuçların tutarlılığını desteklemiştir.




**Şekil 5.28:** RF algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.

**Şekil 5.29-30**'da RF yönteminin 5 ve 6 bantlı ortomozaiklerden üretilen tüm veri setlerine uygulanmasıyla elde edilen tematik haritaların, sınıf bazlı F1 skor değerleri yer almaktadır. Bu grafikler incelendiğinde, öncelikli olarak veri setine bağlı olarak değişen sınıf doğrulukları hakkında bilgiler çıkarılabilmektedir. Özellikle NDYM verisinin dahil olduğu V3 ve V4 veri setindeki beton çatı ve yol sınıfındaki doğruluk artışı göze çarpmakta ve tasarlanan veri setlerinin sınıflandırma doğruluğu üzerindeki etkisi net bir şekilde ortaya koyulmaktadır. 5-bantlı ortomozaik kaynağından oluşturulan V3 veri setinde, V2 veri setine kıyasla beton çatı sınıfı %12.7, yol sınıfı ise %8.3 oranında doğruluk artışı göstermiştir. 6-bantlı veri ile gerçekleştirilen karşılaştırmalı analizde ise benzer şekilde V3 veri setinin beton çatı sınıfında %12.1, yol sınıfında %8.1 doğruluk artışı sağladığı belirlenmiştir.

5 ve 6 bantlı ortomozaikle gerçekleştirilen üretimlerde yükseklik bilgisinin bisiklet yolu sınıfı hariç tüm sınıflar için doğruluk artışı sağladığı ve her iki veri kaynağının da benzer eğilimlere sahip olduğu görülmüştür. Bisiklet yolu sınıfı için gerçekleştirilen analizde, yükseklik bilgisinin veri setine dahil oluşu, görüntü objelerinin bu sınıfla eş kotlu toprak ve yol sınıfına geçişine neden olmuştur. Bu durum doğruluk oranındaki düşüşün temel sebebini oluşturmuştur. Seyrek bitki örtüsü sınıfı, tüm veri setleri içinde %79'luk bir doğruluk oranıyla en düşük performansı sergileyerek, tüm sınıflar arasında ayrımı en zor olan sınıf olarak belirlenmiştir. Öte yandan, kırmızı çatı sınıfı, veri setlerinden bağımsız olarak %98'lik bir doğruluk oranıyla en yüksek doğruluk seviyesini elde eden sınıf olarak öne çıkmıştır.



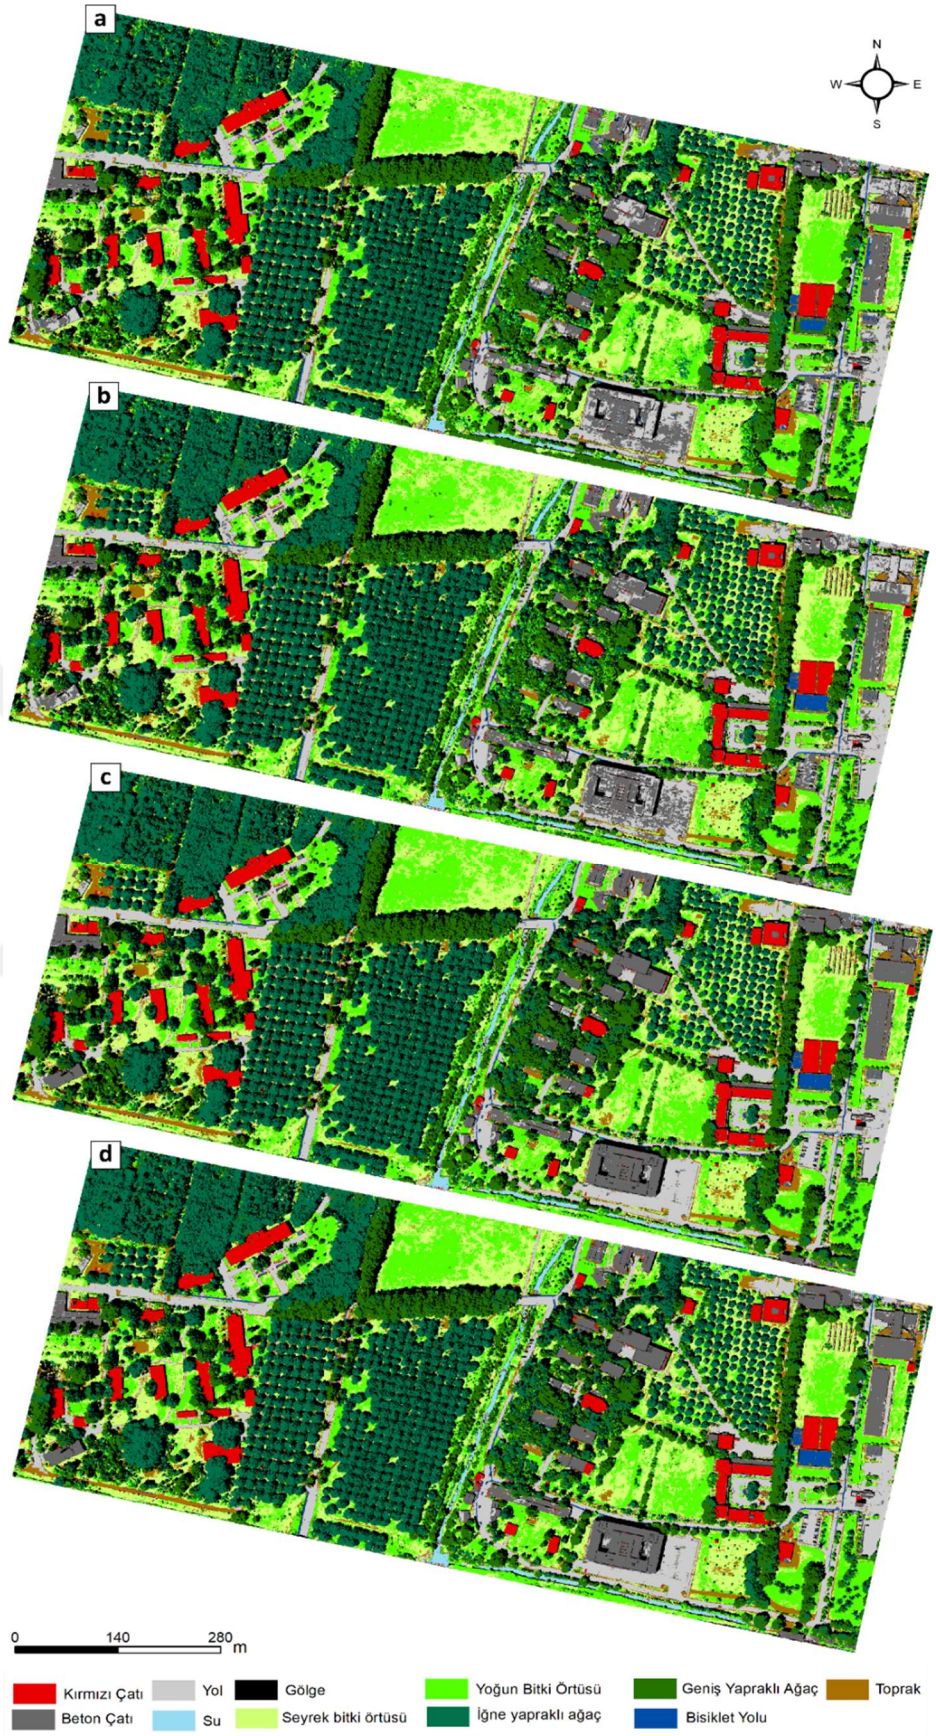
**Şekil 5.29:** 5-bant RF F1 skor değeri.



Şekil 5.30: 6-bant RF F1 skor değeri.

## 5.6.2. Destek Vektör Makineleri

Tez kapsamında AÖ/AK sınıflarının belirlenmesinde SVM yöntemi uygulanmıştır. Özyinelemeli özellik seçimi algoritmasının uygulanmasıyla yalnızca NLI, ARI1, RI indislerinin etkisinin ihmal edilebilir boyutta olduğu belirlenmiş ve V4 veri setine dahil edilmemiştir. Tüm veri setlerine ait tematik harita sonuçları Şekil 5.31-32’de gösterilmiştir. Haritalar incelendiğinde fıstık çamı ağaçlarının dahil olduğu iğne yapraklı ağaç ve çınar ağaçlarının dahil olduğu geniş yapraklı ağaç sınıflarının tüm veri setlerinde yüksek başarı ile sınıflandırıldığı görülebilmektedir. RF’nin kırmızı çatı sınıfı için gösterdiği performans aynı şekilde burada da görülebilmektedir. Bu sınıfın belirlenmesinde spektral ve indis bilgilerinin yeterli olduğu çıkarımı, SVM sınıflandırıcısı için de geçerliliğini korumuştur. Haritaların doğusunda kalan bölgeler incelendiğinde ise yükseklik bilgisinin mevcut olmadığı V1 ve V2 veri setlerinin beton çatı ve yol sınıfı arasındaki ayırmada zorlandığı ve düşük performans gösterdiği görülmektedir.



Şekil 5.31: 5-bantlı ortomozaik veri ve SVM algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c), V4 (d) veri setleri için üretilen tematik haritalar.




**Şekil 5.32:** 6-bantlı ortomosaik veri ve SVM algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.


Şekil 5.33-34'te yer alan grafikler, SVM ile gerçekleştirilen tematik harita üretim sonuçlarının veri seti ve sınıf bazlı F1 skor değerlerini ifade etmektedir. Sınıflara ait doğruluk değerleri incelendiğinde, RF algoritmasına kıyasla daha düşük başarılarla ulaşıldığı görülmüştür. Özellikle 6-bantla gerçekleştirilen sınıflandırmada bisiklet

sınıfında %65.9 değeri ile en düşük doğruluk değeri görülmüş ve bu sınıfın ayırımında 5-bantlı ortomozaik kaynağının kullanımının daha iyi sonuçlar ürettiği belirlenmiştir.

Doku ve geometri özelliklerini içermeyen V1 veri seti beton çatı, yol ve bisiklet yolu sınıflarında en düşük performansı göstermiştir. Yükseklik bilgisinin dahil olduğu V3 ve V4 veri setinde, RF algoritmasındaki sonuçlara benzer şekilde sınıfların genelinde doğruluk artışı yaşanmıştır. V1 veri setinde bisiklet yolu %71.2 değeri ile en düşük sınıflandırma doğruluğunu gösteren sınıf olmuştur, bu sınıf için geometri ve doku özelliklerinin dahil olduğu V2 veri setinde %17 oranında doğruluk artışı gözlemlenmiştir. 5-bantlı ortomozaik kaynağından oluşturulan V3 veri setinde, V2 veri setine kıyasla beton çatı sınıfı %18.5, yol sınıfı ise %15 oranında doğruluk artışı göstermiştir. 6-bantlı veri ile gerçekleştirilen karşılaştırmalı analizde ise benzer şekilde V3 veri setinin beton çatı sınıfında %15.4, yol sınıfında %12.9 doğruluk artışı sağladığı belirlenmiştir.




Şekil 5.33: 5-bant SVM F1 skor değeri.



Şekil 5.34: 6-bant SVM F1 skor değeri.

Şekil 5.35 iki farklı bina yapısı için SVM ile gerçekleştirilen sınıflandırma sonuçlarının veri setlerine bağlı sonuçlarını ve aynı alanı içeren referans görselini içermektedir. Bu şekil incelendiğinde, birinci referansa ait sonuçlarda RF yönteminin aksine V1 ve V2 veri seti özelinde 5 ve 6 bantlı ortomozaik kaynaklarından üretilen

sınıflandırma sonuçlarındaki farklıların daha belirgin ve anlamlı olduğu görülmektedir. Ancak aynı durum ikinci referans objede görülememiş ve bu durumun istisnai olduğu sonucuna varılmıştır.



Şekil 5.35: SVM algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.

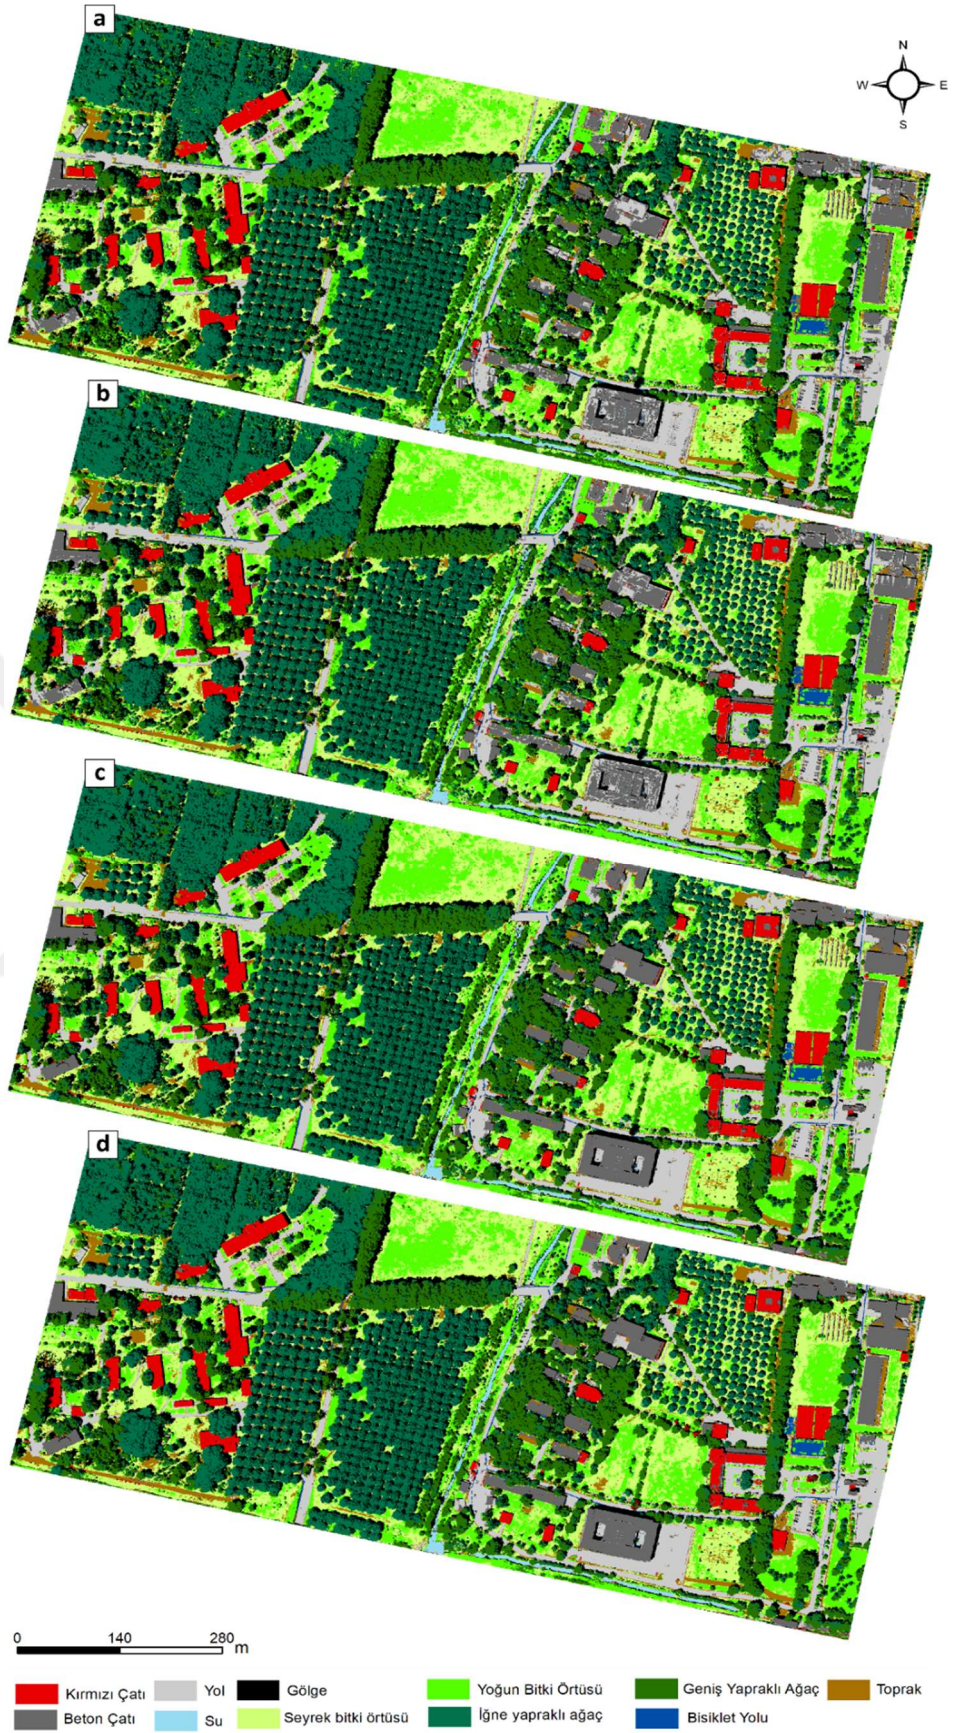
### 5.6.3. Aşırı Gradyan Artırma

Tez kapsamında AÖ/AK sınıflarının belirlenmesinde XGBoost yöntemi uygulanmıştır. Özyinelemeli özellik seçimi algoritmasının uygulanmasıyla **Tablo 5.12**'de belirtilen özelliklerin sınıflandırma üzerindeki etkisinin ihmal edilebilir boyutta olduğu belirlenmiş ve tasarlanan V4 veri setine dahil edilmemiştir.

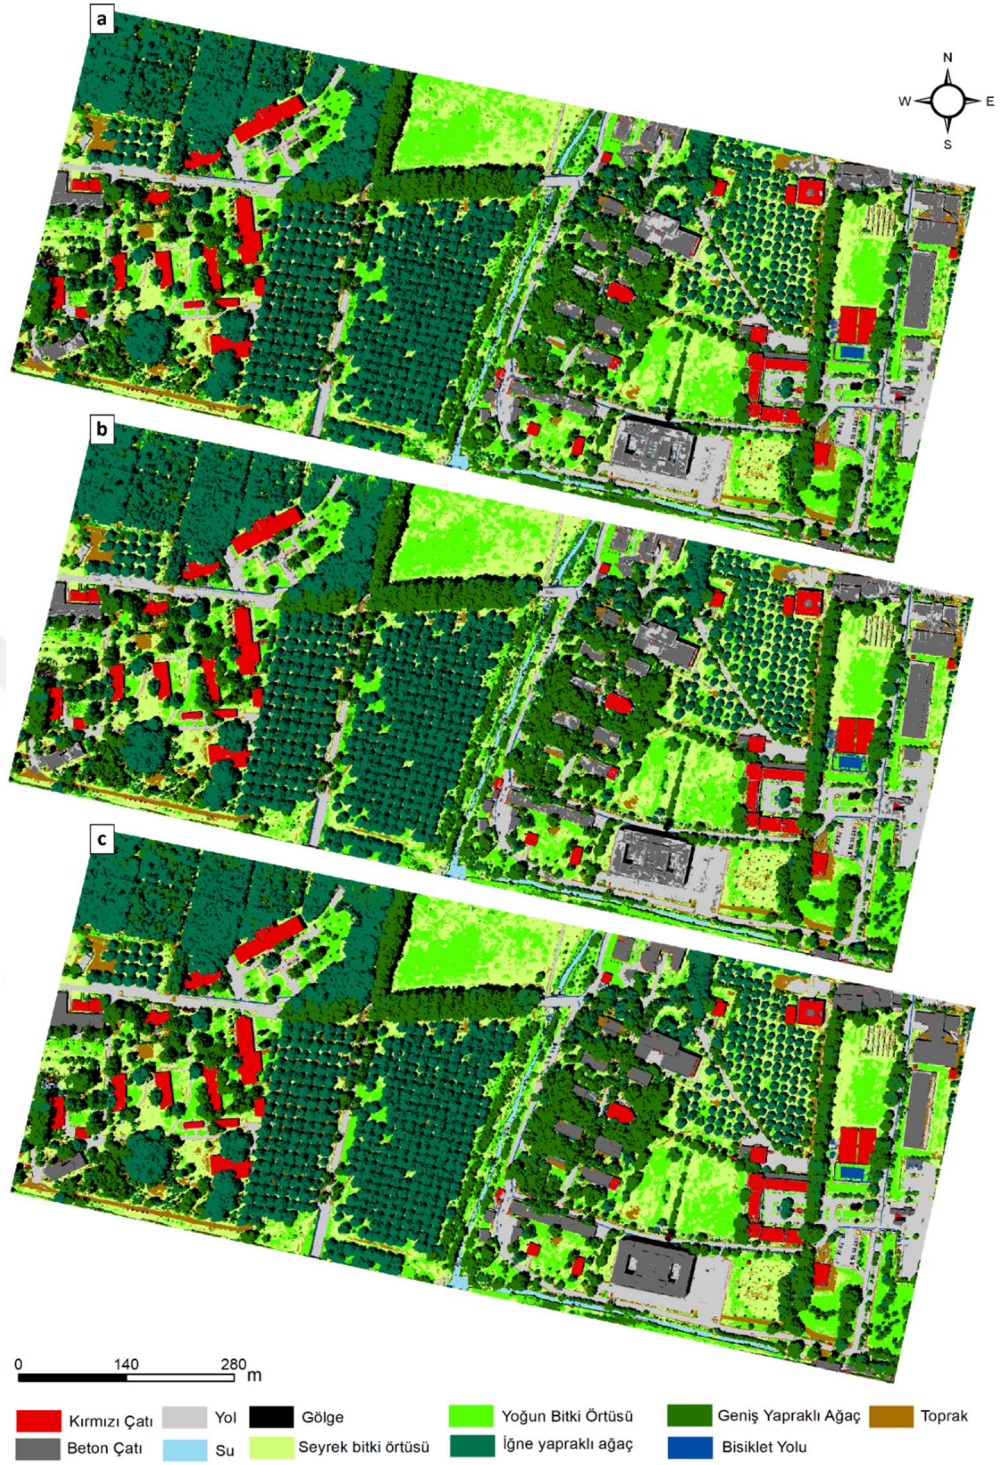
**Tablo 5.12:** XGBoost için özyinelemeli özellik seçimi yöntemi ile belirlenen özellikler.

İndis	Doku	Geometri
MSR	Açısal ikinci moment	Bütünlük
MSAVI2	Entropi	Sınır uzunluğu
NDVI		Asimetri
IPVI		Yoğunluk
		Dikdörtgen
		Ana Doğrultu

**Tablo 5.12** incelendiğinde özyinelemeli özellik seçimi yöntemi, RF'de üretilen sonuçlara benzer şekilde geometrik özelliklerin büyük çoğunluğunun sınıflandırma işlemi üzerindeki etkisinin çok düşük seviyede olduğunu ortaya çıkarmıştır. Ağaç yapılı model oluşturmaları ve benzer çalışma prensiplerine sahip olmaları, bu iki yönteme ait sonuçların yakınsamasını sağlamış ve SVM'den bağımsız sonuçlar ortaya koymuşlardır. Tüm veri setlerine ait tematik harita sonuçları, **Şekil 5.36-37**'de gösterilmiştir. 5 ve 6-bantlı kaynaklarla gerçekleştirilen sınıflandırmalarda her iki veri kaynağı için de V3 veri seti en doğru AÖ/AK temsilini sağlamıştır.




Şekil 5.36: 5-bantlı ortomozaik veri ve XGBoost algoritmasının kullanımıyla V1 (a) ve V2 (b) veri setleri için üretilen tematik haritalar.



**Şekil 5.37:** 6-bantlı ortomozaik veri ve XGBoost algoritmasının kullanımıyla V1 (a), V2 (b), V3 (c) veri setleri için üretilen tematik haritalar.


**Şekil 5.38** iki farklı bina yapısı için XGBoost ile gerçekleştirilen sınıflandırma sonuçlarının veri setlerine bağlı sonuçlarını ve aynı alanı içeren referans görselini içermektedir. Bu şekil incelendiğinde, önceki sınıflandırıcılarda olduğu gibi V3 veri setinin üstün başarı gösterdiği açık bir şekilde görülebilmektedir. Her iki referans obje

için de 5 ve 6 banlı ortomozaik kaynağıyla üretilen sınıflandırma sonuçlarında, görsel olarak anlamlı farklılıklar olmadığı görülmüştür.




Şekil 5.38: XGBoost algoritmasının üç farklı veri seti için iki farklı bina yapısına ait ürettiği tematik harita sonuçları.

**Şekil 5.39-40**'ta yer alan grafikler, XGBoost ile gerçekleştirilen tematik harita üretim sonuçlarının veri seti ve sınıf bazlı F1 skor değerlerini ifade etmektedir. Sınıflara ait doğruluk değerleri incelendiğinde, seyrek bitki örtüsü sınıfı tespitinin tüm veri setlerinde en düşük başarı oranına sahip olduğu görülmektedir. En yüksek başarı ise %97.9 F1 skor değeri ile yol sınıfında yakalanmıştır. Önceki sınıflandırıcılarda olduğu gibi V3 ve V4 veri setlerinde sınıfların genelinde doğruluk artışı sağlanmıştır. 5-bantlı ortomozaik kaynağıyla gerçekleştirilen sınıflandırmada yükseklik bilgisi içeren V3 veri seti V2 veri setine kıyasla, beton çatı sınıfında %9.5, yol sınıfında ise %8.7 oranında bir doğruluk artışı göstermiştir. 6-bantlı sınıflandırmada da yükseklik bilgisi benzer doğruluk artışlarını sağlamıştır, beton çatı ve yol sınıfı için sırasıyla %95.5 ve %98.2 değerleriyle maksimum doğruluklara ulaşılmıştır.



**Şekil 5.39:** 5-bant XGBoost F1 skor değeri.



**Şekil 5.40:** 6-bant XGBoost F1 skor değeri.

#### 5.6.4. Tematik Harita Doğruluk Değerlendirmesi ve Bulgular

Bu başlık altında, tematik harita sonuçlarının incelenmesiyle elde edilen bulgular ve ortaya çıkan sonuçlara dair yorumlar ifade edilmektedir. **Tablo 5.13**'te üretimi tamamlanan tüm tematik haritaların F1 skor ve genel doğruluk metrikleri ile belirlenen

değerlendirme sonuçları yer almaktadır. 5-bant ve 6-bant kavramları önceki bölümlerde açıklandığı üzere NDYM'nin segmentasyon sürecine dahil olduğu ve olmadığı veri kaynaklarını temsil etmektedir.

6-bantlı ortomozaik kaynağı ile gerçekleştirilen segmentasyon süreci ve tasarlanan V3 veri setinin, XGBoost algoritması ile sınıflandırıldığı yaklaşımda %94.52 F1 skor ve %94.65 genel doğruluk değerleri ile tüm varyasyonlar ve tematik harita üretimleri arasında maksimum doğruluğa ulaşılmıştır. 6-bantlı kaynakla üretilen tematik haritaların istatistiki analizinde, 5-bantlı kaynağa kıyasla daha doğru sonuçların elde edilebildiği görülmüştür. Tüm sınıflandırıcılarda V1 veri seti en düşük genel doğruluk ve F1 skor değerini gösterirken V3 ve V4 veri setleri en yüksek doğruluk değerlerini üretmiştir.


**Tablo 5.13:** Tematik doğruluk değerlendirmesi.

<b>5-Bant</b>				
<b>Tematik doğruluk değerlendirmesi (% F1 skor/Genel doğruluk)</b>				
<b>Sınıflandırıcı</b>	<b>V1</b>	<b>V2</b>	<b>V3</b>	<b>V4</b>
<b>RF</b>	89.10 / 89.10	89.54 / 89.49	94.03 / 94.16	93.87 / 94.01
<b>SVM</b>	85.04 / 85.00	85.23 / 85.23	92.65 / 92.81	92.69 / 92.83
<b>XG</b>	89.56 / 89.63	90.31 / 90.35	93.83 / 93.97	93.84 / 93.98

<b>6-Bant</b>			
<b>Tematik doğruluk değerlendirmesi (% F1 skor/Genel doğruluk)</b>			
<b>Sınıflandırıcı</b>	<b>V1</b>	<b>V2</b>	<b>V3</b>
<b>RF</b>	90.00 / 89.99	90.42 / 90.37	94.47 / 94.59
<b>SVM</b>	85.44 / 85.44	86.42 / 86.45	92.49 / 92.32
<b>XG</b>	90.49 / 90.48	90.76 / 90.73	<b>94.52 / 94.65</b>

**Şekil 5.41** tematik haritaların istatistiki analizlerinin grafik gösterimini içermektedir. Grafik incelendiğinde RF ve XGBoost algoritmaları genel dağılımda yakınsak sonuçlar gösterirken, SVM algoritmasının sınıflandırıcılar arasında en düşük performansı gösterdiği net bir şekilde görülmektedir.




**Şekil 5.41:** AÖ/AK tematik haritalarının veri setine göre doğruluk analizleri.

**Şekil 5.42** sınıflandırma süreci boyunca en yüksek performans gösteren XGBoost ve V3 veri setiyle üretilen tematik haritada faydalanılan tüm özelliklerin, sonuç harita üzerindeki ağırlığının sınıf bazlı gösterimini ifade etmektedir. Şeklin yorumlanabilirliğini kolaylaştırmak adına içeriğinde tüm özellikler arasındaki en yüksek etkiye sahip 20 özellik ve en az etkili 20 özelliğe yer verilmiştir. Bu grafik incelendiğinde:

- NDYM'nin özellikle beton çatı sınıfı üzerindeki etkisinin net bir şekilde ortaya konulduğu,
- NDYM özelliği grafikte en üst sırada konumlanmış ve tüm özellikler arasında en yüksek etkiye sahip olmuştur. RGR, PSRI, BRI indislerinin ise bu özelliği takip eden yüksek etkili özellikler arasında yer aldığı,
- Kırmızı çatı ve toprak sınıfı için RGR ve VEG indislerinin son derece etkili olduğu,
- Parlaklık ve RI özelliğinin gölge sınıfında doğrudan etkili olduğu,
- YKÖ bantının sağladığı spektral bilginin yol ve bitki sınıfları için büyük oranda fayda sağladığı,
- ER, NLI indislerinin yol sınıfının tespitinde yüksek etkiye sahip olduğu,
- NDVI, MVI, IPVI, MSAVI2 gibi vejetasyon indislerinin sınıflar arası ayırmada çok düşük etkiye sahip olduğu,

- Geometrik özelliklerin tamamının en düşük etkiye sahip 20 özellik arasında yer aldığı

gibi AÖ/AK çalışmaları için fayda sağlayacak oldukça etkili çıkarımlar elde edilebilmiştir.



**Şekil 5.42:** Sınıf bazlı SHAP analizi sonucu: (a) En etkili özellikler, (b) en düşük etkiye sahip özellikler.

Tüm sınıflandırıcılar ve veri setleri ile üretilen tematik haritaların görsel ve istatistikî analizleri neticesinde:

- V3 veri seti ile gerçekleştirilen uygulamalarda V1, V2 veri setine kıyasla, RF, SVM, XGBoost olmak üzere tüm sınıflandırıcılarda performans artışı görülmüştür. Yükseklik bilgisinin dahil edildiği V3 veri setinde, doğruluk artışının tüm sınıflar için geçerli olduğu belirlenmiştir. Bu bulgular ışığında, obje tabanlı gerçekleştirilen sınıflandırma çalışmalarındaki performans artırımı için uygulanan yaklaşım, oldukça başarılı sonuçlar ortaya koymuştur.
- Özyinelemeli özellik seçimi yöntemi ile tasarlanan V4 veri seti, V3 veri setinin sınıf çıkarımında gösterdiği performansa oldukça benzer değerler ortaya koymuştur. Böylelikle özyinelemeli özellik seçimi yöntemiyle, sınıflandırma üstünde etkisiz ya da etkisi ihmal edilebilir boyutta olarak belirlenen ve V4 veri setine dahil edilmeyen özelliklerin başarılı ve tutarlı bir şekilde tanımlanabildiği görülmüştür.

- NDYM verisinin yalnızca sınıflandırma sürecine dahil edilmesinin yanı sıra sınıflandırma ve segmentasyon sürecinin her ikisine de dahil edildiği XGBoost ile gerçekleştirilen sınıflandırma yaklaşımının %94.51 F1 skor ve %94.65 genel doğruluk değeri ile tüm veri setleri ve sınıflandırıcılara kıyasla üstün performans sağladığı görülmüştür.
- Bisiklet yolu gibi sürekliliğini koruyan unsurları içeren sınıfların çıkarımında, SVM algoritmasının tercih edildiği uygulamalarda, doku ve geometri özelliklerinin önem kazandığı belirlenmiştir. Doku ve geometrinin dahil edildiği V2 veri setinde bisiklet yolu sınıfında 5 bantlı sınıflandırma işleminde %17, 6 bantlı sınıflandırma da ise %12 oranında doğruluk artışı tespit edilmiştir **Şekil 5.33-34**. Bu durumun aksine yol sınıfı için aynı artışın sağlanmadığı görülmüş ve buna sebep olarak bu sınıfın ayırımındaki esas problemin beton çatılı yapılarla olan spektral benzerlik problemi olduğu düşünülmüştür. SVM için gerçekleştirilen özellik seçimi işleminde, geometrik ve doku özelliklerinin sınıflandırma sonucu üzerinde etkili olduğu belirlenirken, XGBoost ve RF algoritmalarında bu durumun tersi söz konusu olmuştur. XGBoost ve RF algoritmaları geometrik özelliklerin sınıflandırma üzerinde ihmal edilebilir etkisinin olduğunu ortaya koymuş ve ilgili grafikler incelendiğinde SVM'nin aksine ciddi bir doğruluk artışı görülmemiştir.
- XGBoost ve V3 veri seti için gerçekleştirilen SHAP analizi sonucunda belirlenen en düşük etkili özellikler, ağırlıklı olarak geometrik ve vejetasyon indisi özelliklerinden oluşmaktadır, bu özellikler daha öncesinde özyinelemeli özellik seçimi yöntemiyle etkisiz olarak belirlenen özelliklerle tam uyuşum göstermiştir. İki farklı yöntemin ortaya koyduğu eş sonuçlar, bu özelliklerin sınıflandırma sürecine fayda sağlamadığı kanısını desteklemektedir. En yüksek performansı gösteren XGBoost algoritmasında, segmentlerin alan, uzunluk vb. geometrik özelliklerinin, sınıf etiketinin tespitinde bir katkı sağlamadığı belirlenmiştir.
- F1 skor değerine bağlı olarak gerçekleştirilen sınıf bazlı doğruluk değerlendirmelerinde, seyrek bitki örtüsü ve bisiklet yolu sınıfları en düşük doğruluk değerlerini göstermiştir. Tüm sınıflandırıcılar değerlendirildiğinde en düşük doğruluk değerlerinin tamamının, V1 veri seti ile gerçekleştirilen uygulamalarda olduğu görülmüştür. 11 sınıflı çalışmada, SVM ve V1 veri setinin kullanımında bisiklet yolu sınıfı %65.9 değeri ile çalışmanın en düşük doğruluğunu göstermiştir. V1 veri setinin RF ve XGBoost ile sınıflandırıldığı

yaklaşımında, seyrek bitki örtüsü sınıfı sırasıyla %78.3 ve %79.4 değerleri ile tespit edilebilmiş ve bu değerler %65.9 değerini takip eden en düşük performanslı sınıflandırma sonuçları olmuştur.

- En düşük doğruluğu gösteren bisiklet yolu sınıfı özelinde sonuçlar incelendiğinde, **Tablo A.8-9** da yer alan hata matrisinde görülebileceği üzere SVM algoritmasının, bu sınıfın beton çatı sınıfından ayırımında düşük performans gösterdiği belirlenmiştir.
- Çalışma alanı ve veri seti özelinde sınıflar arası ayırimda NDYM en büyük öneme sahip özellik olarak belirlenirken, NDVI indisi en düşük öneme sahip özellik olmuştur. Tez çalışması için belirlenen çalışma bölgesinin ağırlıklı olarak yoğun bitki örtüsü ile kaplı olması, tanımlı sınıflar arasında dört farklı vejetasyon sınıfının yer alması gibi hususların NDVI indisinin sınıf ayırımındaki etkisini azalttığı ve en düşük etkideki özellik olarak ortaya çıkmasına sebep olduğu düşünülmektedir.
- NDYM'nin eğimli yüzeylerde değişkenlik gösteren yükseklik bilgisi, eş ya da benzer spektral özellikli alanlarda segment yapısı üzerinde bozucu etki oluşturabilmektedir. NDYM verisinin dahil olduğu sınıflandırma çalışmalarında, AÖ/AK sınıfları içerisinde yer alan objelerin biçimsel yapıları iyi analiz edilmeli ve bant ağırlığının belirlenmesinde bu husus dikkate alınmalıdır.

## 6. SONUÇLAR

Yeryüzünde meydana gelen değişimlerin hızlı ve güvenilir bir araç ile gözlemlenmesi; doğal afetlerin analizi, kentsel kalkınma planlarının üretimi, bitki sağlığı gözlemi gibi birçok çalışma konusu için son derece önemlidir. İdeal veri kaynağı, ihtiyaç duyulan doğruluk seviyesi ve çalışma bölgesinin büyüklüğüne bağlı olarak değişkenlik göstermektedir. Bu noktada AÖ/AK haritaları temel bilgi kaynağını oluşturmakta ve yüksek doğrulukta hazırlanmaları hususunda uzay ve hava kaynaklı çeşitli araçlar kullanılmaktadır.

Tez çalışması kapsamında yüksek çözünürlüklü veri kaynağının altlık olarak kullanılması ve bu kaynaktan türetilen birçok yardımcı verinin farklı kombinasyonlar halinde sınıflandırma sürecine dahil edilmesi yaklaşımıyla, çok sınıflı bir sınıflandırma problemi için performans artırımı amaçlanmıştır. Bu hedef doğrultusunda yüksek çözünürlüklü multispektral İHA kaynağından temin edilen görüntülerin işlenmesi ile AÖ/AK haritalarının üretimi gerçekleştirilmiştir. Fotogrametrik veri üretimi, makine öğrenmesi algoritmalarının uygulanmasıyla gerçekleştirilen sınıflandırma süreci ve sonuç tematik haritaların doğruluk analizi gibi işlem adımlarının her biri detaylı bir şekilde ele alınmıştır ve çalışmanın amaçlanan çıktıları kapsamında değerlendirilmiştir. Obje tabanlı görüntü analizi yaklaşımı literatürde belirtildiği gibi yüksek çözünürlüklü veriler için oldukça anlamlı görüntü objeleri üretmiş ve sınıflandırma sonuçlarına pozitif katkı sağlamıştır. 5-bantlı ortomozaik ve bu görüntüye ek bant olarak tanımlanan NDYM verisinden oluşan 6-bantlı ortomozaik segmentasyon sürecine ayrı ayrı dahil edilmiştir. Görüntü objeleri; spektral, doku, geometri, indis ve NDYM verisinden tasarlanan toplamda 69 adet özellik içeren dört farklı veri seti ve RF, SVM, XGBoost algoritmaları ile sınıflandırılmıştır. Bu veri setleri ve sınıflandırma algoritmalarının kullanımıyla 21 farklı senaryo için tematik harita üretim işlemi gerçekleştirilmiştir.

Tematik haritaların analizi neticesinde 6-bantlı segmentasyon sonucu ve tüm özelliklerin dahil olduğu veri setine (V3) uygulanan XGBoost algoritması, üstün performans göstererek en yüksek genel doğruluk değerini üretmiştir. RF algoritması ise çok yakın genel doğruluk sonucu üretirken, SVM algoritması en düşük performansı göstermiştir. 5-bant ve 6-bant görüntülerin bağımsız değerlendirilmesiyle doğruluk

oranlarında deęişimlerin meydana geldięi görülmüştür. NDYM bandının segmentasyon sürecinde önemli bir ek bilgi kaynaęı sağladığı ve görüntü objelerinde boyut artışıyla tutarlılık sağlayarak, sınıflandırılacak obje sayısını azalttığı tespit edilmiştir.

Görsel ve istatistiki analizlerin tamamlanmasıyla, tez kapsamında hedeflenen performans artırımının başarılı bir şekilde elde edildięi belirlenmiştir. Tüm çalışmalar neticesinde, yüksek çözünürlüklü bir veri kaynaęı ile gerçekleştirilen çok sınıflı bir AÖ/AK haritası için en doğru veri seti ve sınıflandırıcı yaklaşımı belirlenmiştir.

Birçok bulgunun çıkarıldığı bir dizi analizden elde edilen sonuçlar, çeşitli amaçlar ya da çalışma alanları için uygulanacak tematik harita üretimlerinde, iş akış sürecine yardımcı olabilecek niteliktedir. Özellikle beton çatı ve yol sınıflarındaki doğruluk artışında, yükseklik verisinin AÖ/AK haritalarının üretim aşamalarında efektif şekilde kullanımının son derece olumlu etkilere sahip olduğu tespit edilmiştir. Bu nedenle, yükseklik bilgisinin doğruluęu sınıflandırma çalışmalarında büyük önem arz etmekte ve NDYM gibi hassas modellerin üretiminde en doğru yaklaşımın uygulanması gerekmektedir. Tez çalışması kapsamında uygulanan yaklaşımın gelecekte yapılması planlanan benzer çalışmalar için referans niteliğinde olması beklenmektedir.

## KAYNAKLAR

Agisoft, (2022), “Agisoft Metashape User Manual Professional Edition, Version 1.8”, User Manuals, Agisoft LLC, St. Petersburg, Russia.

Agüera-Vega F., Carvajal-Ramírez F., Martínez-Carricondo P., (2017). Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle. *Measurement*, 98, 221-227.

Ali F., (2015), “Urban classification by pixel and object-based approaches for very high resolution imagery”, MSc thesis, University of GAVLE.

Al-Najjar H. A., Kalantar B., Pradhan B., Saeidi V., Halin A. A., Ueda N., Mansor S., (2019). Land cover classification from fused DSM and UAV images using convolutional neural networks. *Remote Sensing*, 11 (12), 1461.

Assmann J. J., Kerby J. T., Cunliffe A. M., Myers-Smith I. H., (2018). Vegetation monitoring using multispectral sensors—best practices and lessons learned from high latitudes. *Journal of Unmanned Vehicle Systems*, 7 (1), 54-75.

Atkinson Amorim J. G., Schreiber L. V., de Souza M. R. Q., Negreiros M., Susin A., Bredemeier C., Parraga A., (2022). Biomass estimation of spring wheat with machine learning methods using UAV-based multispectral imaging. *International Journal of Remote Sensing*, 43 (13), 4758-4773.

Atkinson P. M., Lewis P., (2000). Geostatistical classification for remote sensing: an introduction. *Computers & Geosciences*, 26 (4), 361-371.

Attri P., Chaudhry S., Sharma S., (2015). Remote sensing & GIS based approaches for LULC change detection—A review. *International Journal of Current Engineering and Technology*, 5, 3126-3137.

Aval J., Fabre S., Zenou E., Sheeren D., Fauvel M., Briottet X., (2019). Object-based fusion for urban tree species classification from hyperspectral, panchromatic and nDSM data. *International Journal of Remote Sensing*, 40 (14), 5339-5365.

Baatz M., Hoffmann C., Willhauck G., (2008), “Progressing from object-based to object-oriented image analysis”, In: T. Blaschke, S. Lang, G. Hay, Editors, “Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications”, Springer Berlin Heidelberg.

Baatz M, Schäpe A. 2000., “Multiresolution segmentation: An optimization approach for high quality multi-scale image segmentation”, *Angewandte Geographische Informations-Verarbeitung*, XII; Wichmann Verlag, Berlin, Germany.

Bah M. D., Hafiane A., Canals R., (2018). Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. *Remote Sensing*, 10 (11), 1690.

Banerjee B. P., Sharma V., Spangenberg G., Kant, S., (2021). Machine learning regression analysis for estimation of crop emergence using multispectral UAV imagery. *Remote Sensing*, 13 (15), 2918.

Bannari A., Morin D., Bonn F., Huete A., (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13 (1-2), 95-120.

Barrero O., Perdomo S. A., (2018). RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. *Precision Agriculture*, 19, 809-822.

Bayaslı, B., (2021), “Hava Lidar Verilerinin Yapay Zeka Yöntemleri Kullanılarak Sınıflandırılması ve Filtrelenmesi”, Yüksek Lisans Tezi, YTÜ.

Belcore E., Piras M., Pezzoli A., (2022). Land Cover Classification from Very High-Resolution UAS Data for Flood Risk Mapping. *Sensors*, 22 (15), 5622.

Belgiu M., Drăguț L., (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.

Bendig J., Yu K., Aasen H., Bolten A., Bennertz S., Broscheit J., Bareth, G., (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87.

Ben-Hur A., Weston J., (2010). A user’s guide to support vector machines. *Data Mining Techniques for the Life Sciences*, 609, 223-239.

Beniwal S., Arora J., (2012). Classification and feature selection techniques in data mining. *International Journal of Engineering Research & Technology*, 1 (6), 1-6.

Beumier C., Idrissa M., (2016). Digital terrain models derived from digital surface model uniform regions in urban areas. *International Journal of Remote Sensing*, 37 (15), 3477-3493.

Bhatt P. P., (2022), “Fine Scale Mapping of Laurentian Mixed Forest Natural Habitat Communities Using Multispectral NAIP and UAV Datasets Combined with Machine Learning Methods”, PhD thesis, Michigan Technological University.

Bithas P. S., Michailidis E. T., Nomikos N., Vouyioukas D., Kanatas A. G., (2019). A survey on machine-learning techniques for UAV-based communications. *Sensors*, 19 (23), 5170.

Blaschke T., (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65 (1), 2-16.

Blaschke T., Hay G. J., Kelly M., Lang S., Hofmann P., Addink E., Tiede D., (2014). Geographic object-based image analysis—towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 180-191.

Blaschke T., Strobl J., (2001). What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. *Zeitschrift für Geoinformationssysteme*, 12-17.

Boegh E., Soegaard H., Broge N., Hasager C. B., Jensen N. O., Schelde K., Thomsen A., (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture. *Remote sensing of Environment*, 81 (2-3), 179-193.

Bolon-Canedo V., Remeseiro B., (2020). Feature selection in image analysis: a survey. *Artificial Intelligence Review*, 53 (4), 2905-2931.

Boulesteix A. L., Janitza S., Kruppa J., König I. R., (2012). Overview of random forest methodology and practical guidance with emphasis on computational biology and bioinformatics. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2 (6), 493-507.

Breiman L., (2001). Random forests. *Machine learning*, 45, 5-32.

Breiman, L., (2002), "Manual on setting up, using, and understanding random forests v3. 1", Statistics Department University of California Berkeley, CA, USA, 1 (58), 3-42.

Broge N. H., Leblanc E., (2001). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*, 76 (2), 156-172.

Budholiya K., Shrivastava S. K., Sharma V., (2022). An optimized XGBoost based diagnostic system for effective prediction of heart disease. *Journal of King Saud University-Computer and Information Sciences*, 34 (7), 4514-4523.

Bufebo B., Elias E., (2021). Land use/land cover change and its driving forces in Shenkolla watershed, south Central Ethiopia. *The Scientific World Journal*, 2021.

Burley T. M., (1961). Land use or land utilization?. *The Professional Geographer*, 13 (6), 18-20.

Cai J., Luo J., Wang S., Yang S., (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70-79.

Castilla G., Hay G. J., (2008), "Image objects and geographic objects", In: T. Blaschke, S. Lang, G. Hay, Editors, "Object-based image analysis: Spatial concepts for knowledge-driven remote sensing applications", Springer Berlin Heidelberg.

Castillo S. M. (2020), "Object-Based Land Cover Classification of UAV True Color Imagery", PhD thesis, Florida Atlantic University.

Chauhan N., Kumar R., Mukherjee S., Hazra A., Giri K., (2022). Ultra-resolution unmanned aerial vehicle (UAV) and digital surface model (DSM) data-based automatic extraction of urban features using object-based image analysis approach in Gurugram, Haryana. *Applied Geomatics*, 14 (4), 751-764.

Chen J. M., (1996). Evaluation of vegetation indices and a modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*, 22 (3), 229-242.

Chen T., Guestrin C., (2016), “XGBoost: A Scalable Tree Boosting System”, 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794, San Francisco, CA, USA, 13-17-August.

Chen J., Pan D., Maz Z., (2009). Image-object detectable in multiscale analysis on high-resolution remotely sensed imagery. *International Journal of Remote sensing*, 30 (14), 3585– 3602.

Christiansen M. P., Laursen M. S., Jørgensen R. N., Skovsen S., Gislum R., (2017). Designing and testing a UAV mapping system for agricultural field surveying. *Sensors*, 17 (12), 2703.

Clawson M., Stewart C. L., (1965), “Land use information. A critical survey of US statistics including possibilities for greater uniformity”, The Johns Hopkins Press for Resource for the Future, Baltimore.

Colkesen I., Kavzoglu T., (2016), “Performance evaluation of rotation forest for svm-based recursive feature elimination using hyperspectral imagery”, 8th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 1-5, Los Angeles, USA, 21-24 August.

Colkesen I., Kavzoglu T., Atesoglu A., Tonbul H., Ozturk M. Y., (2023). Multi-seasonal evaluation of hybrid poplar (*P. Deltoides*) plantations using Worldview-3 imagery and state-of-the-art ensemble learning algorithms. *Advances in Space Research*, 71 (7), 3022-3044.

Comert R., Kaplan O., (2018), “Object Based Building Extraction and Building Period Estimation from Unmanned Aerial Vehicle Data” Proceedings of the ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Beijing, China, 7–10 May.

Congalton R., Green K., (1999), “Assessing the Accuracy of Remotely Sensed Data: Principles and Practices”, Boca Raton: Lewis Publishers.

Cortes C., Vapnik V., (1995). Support-vector networks. *Machine Learning*, 20, 273-297.

Cömert R., (2018), “İnsansız Hava Aracı Verilerinden Nesne Tabanlı Sınıflandırma Yaklaşımı ile Sığ Heyelanların Tespiti”, Doktora Tezi, Anadolu Üniversitesi.

Cutler D. R., Edwards Jr T. C., Beard K. H., Cutler A., Hess K. T., Gibson J., Lawler J. J., (2007). Random forests for classification in ecology. *Ecology*, 88 (11), 2783-2792.

Çölkesen İ., (2015), “Yüksek çözünürlüklü uydu görüntüleri kullanarak benzer spektral özelliklere sahip doğal nesnelere ayırt edilmesine yönelik bir metodoloji geliştirme”, Doktora Tezi, İstanbul Teknik Üniversitesi.

Dandois J. P., Olano M., Ellis E. C., (2015). Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. *Remote sensing*, 7 (10), 13895-13920.

Daniels L., Eeckhout E., Wieme J., Dejaegher Y., Audenaert K., Maes W. H., (2023). Identifying the Optimal Radiometric Calibration Method for UAV-Based Multispectral Imaging. *Remote Sensing*, 15 (11), 2909.

Daughtry C. S., Walthall C. L., Kim M. S., De Colstoun E. B., McMurtrey Iii J. E., (2000). Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. *Remote sensing of Environment*, 74 (2), 229-239.

De Castro A. I., Torres-Sánchez J., Peña J. M., Jiménez-Brenes F. M., Csillik O., López-Granados F., (2018). An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. *Remote Sensing*, 10 (2), 285.

De Oliveira Silva L., de Mello Bandeira R. A., Campos V. B. G., (2019). Proposal to planning facility location using UAV and geographic information systems in a post-disaster scenario. *International Journal of Disaster Risk Reduction*, 36, 101080.

Delavarpour N., Koparan C., Nowatzki J., Bajwa S., Sun X., (2021). A technical study on UAV characteristics for precision agriculture applications and associated practical challenges. *Remote Sensing*, 13 (6), 1204.

Definiens, (2006), “Definiens Professional 5 Reference Book”, Definiens, München.

DeFries R. S., Foley J. A., Asner G. P., (2004). Land-use choices: Balancing human needs and ecosystem function. *Frontiers in Ecology and the Environment*, 2 (5), 249-257.

Dehm D., (2019), “A Small Unmanned Aerial System (SUAS) Based Method for Monitoring Wetland Inundation & Vegetation”, MSc thesis, The University of Toledo.

Dey V, Zhang Y, Zhong M., (2010), “A review on image segmentation techniques with remote sensing perspective”, In Proceedings of the ISPRS TC VII Symposium—100 Years ISPRS, Vienna, Austria, 5–7 July.

Dhodhi M. K., Saghri J. A., Ahmad I., Ul-Mustafa R., (1999). D-ISODATA: A distributed algorithm for unsupervised classification of remotely sensed data on network of workstations. *Journal of Parallel and Distributed Computing*, 59 (2), 280-301.

Doughty C. L., Cavanaugh K. C., (2019). Mapping coastal wetland biomass from high resolution unmanned aerial vehicle (UAV) imagery. *Remote Sensing*, 11 (5), 540.

Drăgut L., Tiede D., Levick S. R., (2010). ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International Journal of Geographical Information Science*, 24 (6), 859-871.

- Dubbini M., Curzio L. I., Campedelli A., (2016). Digital elevation models from unmanned aerial vehicle surveys for archaeological interpretation of terrain anomalies: case study of the Roman castrum of Burnum (Croatia). *Journal of Archaeological Science: Reports*, 8, 121-134.
- Duro D. C., Franklin S. E., Dubé M. G., (2012). A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT-5 HRG imagery. *Remote Sensing of Environment*, 118, 259-272.
- Eisank C., Smith M., Hillier J., (2014). Assessment of multiresolution segmentation for delimiting drumlins in digital elevation models. *Geomorphology*, 214, 452-464.
- Eisenbeiß H. (2009), "UAV photogrammetry", PhD thesis, ETH Zurich.
- Eskandari R., Mahdianpari M., Mohammadimanesh F., Salehi B., Brisco B., Homayouni S., (2020). Meta-analysis of unmanned aerial vehicle (UAV) imagery for agro-environmental monitoring using machine learning and statistical models. *Remote Sensing*, 12 (21), 3511.
- Feng Q., Liu J., Gong J., (2015). UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, 7 (1), 1074-1094.
- Fisher P., (1997). The pixel: a snare and a delusion. *International Journal of Remote Sensing*, 18 (3), 679-685.
- Foody G. M., (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80 (1), 185-201.
- Foody G. M., (2004). Thematic map comparison. *Photogrammetric Engineering & Remote Sensing*, 70 (5), 627-633.
- Forghani A., Cechet B., Nadimpalli K., (2007), "Object-based classification of multi-sensor optical imagery to generate terrain surface roughness information for input to wind risk simulation", In 2007 IEEE International Geoscience and Remote Sensing Symposium, 3090-3095, Barcelona, Spain, 23-28 July.
- Frazier A. E., Singh, K. K., (2021), "Fundamentals of capturing and processing drone imagery and data", CRC Press.
- Frey J., Kovach K., Stemmler S., Koch B., (2018). UAV photogrammetry of forests as a vulnerable process. A sensitivity analysis for a structure from motion RGB-image pipeline. *Remote Sensing*, 10 (6), 912.
- Gamon J. A., Surfus J. S., (1999). Assessing leaf pigment content and activity with a reflectometer. *The New Phytologist*, 143 (1), 105-117.
- Gao X., Huete A. R., Ni W., Miura T., (2000). Optical-biophysical relationships of vegetation spectra without background contamination. *Remote Sensing of Environment*, 74 (3), 609-620.

Gao Y. A. N., Mas J. F., Kerle N., Navarrete Pacheco J. A., (2011). Optimal region growing segmentation and its effect on classification accuracy. *International Journal of Remote Sensing*, 32 (13), 3747-3763.

Gaur S., Bandyopadhyay A., Singh R., (2021). Projecting land use growth and associated impacts on hydrological balance through scenario-based modelling in the Subarnarekha basin, India. *Hydrological Sciences Journal*, 66 (14), 1997-2010.

Gil-Docampo M. D. L. L., Arza-García M., Ortiz-Sanz J., Martínez-Rodríguez S., Marcos-Robles J. L., Sánchez-Sastre L. F., (2020). Above-ground biomass estimation of arable crops using UAV-based SfM photogrammetry. *Geocarto International*, 35 (7), 687-699.

Gindraux S., Boesch R., Farinotti D., (2017). Accuracy assessment of digital surface models from unmanned aerial vehicles' imagery on glaciers. *Remote Sensing*, 9 (2), 186.

Giri C.P., (2012), "Remote Sensing of Land Use and Land Cover: Principles and Applications", CRC Press.

Gislason P. O., Benediktsson J. A., Sveinsson J. R., (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27 (4), 294-300.

Gitelson A. A., Merzlyak M. N., Chivkunova O. B., (2001). Optical properties and nondestructive estimation of anthocyanin content in plant leaves. *Photochemistry and Photobiology*, 74 (1), 38-45.

Goel N. S., Qin W., (1994). Influences of canopy architecture on relationships between various vegetation indices and LAI and FPAR: A computer simulation. *Remote Sensing Reviews*, 10 (4), 309-347.

Gualtieri J. A., Cromp R. F., (1999), "Support vector machines for hyperspectral remote sensing classification", In 27th AIPR workshop: Advances in computer-assisted recognition, 221-232, Washington, DC, USA, 14-16 October.

Guidici D., Clark M. L., (2017). One-Dimensional convolutional neural network land-cover classification of multi-seasonal hyperspectral imagery in the San Francisco Bay Area, California. *Remote Sensing*, 9 (6), 629.

Guo Q., Zhang J., Guo S., Ye Z., Deng H., Hou X., Zhang H., (2022). Urban tree classification based on object-oriented approach and random forest algorithm using unmanned aerial vehicle (uav) multispectral imagery. *Remote Sensing*, 14 (16), 3885.

Güran A., Uysal M., Doğrusöz Ö. (2014). Destek vektör makineleri parametre optimizasyonunun duygu analizi üzerindeki etkisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16 (48), 86-93.

Hague T., Tillett N. D., Wheeler H., (2006). Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture*, 7, 21-32.

- Hakala T., Markelin L., Honkavaara E., Scott B., Theocharous T., Nevalainen O., Fox, N., (2018). Direct reflectance measurements from drones: sensor absolute radiometric calibration and system tests for forest reflectance characterization. *Sensors*, 18 (5), 1417.
- Hansen M. C., Potapov P. V., Moore R., Hancher M., Turubanova S. A., Tyukavina A., Townshend J., (2013). High-resolution global maps of 21st-century forest cover change. *Science*, 342 (6160), 850-853.
- Haralick R. M., Shanmugam K., Dinstein I. H., (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 6, 610-621.
- Hartmann W., Havlena M., Schindler K., (2016). Recent developments in large-scale tie-point matching. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 47-62.
- Hayes M. M., Miller S. N., Murphy M. A., (2014). High-resolution landcover classification using Random Forest. *Remote sensing letters*, 5 (2), 112-121.
- He J., Li Y., Zhang K., (2012). Research of UAV flight planning parameters. *Positioning*, 3, 43-45.
- Hossain M. D., Chen D., (2019). Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 115-134.
- Hsu C. W., Lin C. J., (2002). A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks*, 13 (2), 415-425.
- Huang C., Davis L. S., Townshend J. R. G., (2002). An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23 (4), 725-749.
- Huang X., Xie C., Fang X., Zhang L., (2015). Combining pixel-and object-based machine learning for identification of water-body types from urban high-resolution remote-sensing imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8 (5), 2097-2110.
- Huete A., Didan K., Miura T., Rodriguez E. P., Gao X., Ferreira L. G., (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83 (1-2), 195-213.
- Hughes G., (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14 (1), 55-63.
- Hunt Jr E. R., Rock B. N., (1989). Detection of changes in leaf water content using near-and middle-infrared reflectances. *Remote Sensing of Environment*, 30 (1), 43-54.

Huo L. Z., Silva C. A., Klauberg C., Mohan M., Zhao L. J., Tang P., Hudak A. T., (2018). Supervised spatial classification of multispectral LiDAR data in urban areas. *PloS One*, 13 (10), e0206185.

Hussain M., Chen D., Cheng A., Wei H., Stanley D., (2013). Change detection from remotely sensed images: From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80, 91-106.

Husson E., Reese H., Ecke F., (2017). Combining spectral data and a DSM from UAS-images for improved classification of non-submerged aquatic vegetation. *Remote Sensing*, 9 (3), 247.

Iizuka K., Itoh M., Shiodera S., Matsubara T., Dohar M., Watanabe K., (2018). Advantages of unmanned aerial vehicle (UAV) photogrammetry for landscape analysis compared with satellite data: A case study of postmining sites in Indonesia. *Cogent Geoscience*, 4 (1), 1498180.

Jacobsen K. (2014). Development of large area covering height model. The International Archives of the Photogrammetry, *Remote Sensing and Spatial Information Sciences*, XL-4, 40 (4), 105-110.

James M. R., Robson S., (2014). Mitigating systematic error in topographic models derived from UAV and ground-based image networks. *Earth Surface Processes and Landforms*, 39 (10), 1413-1420.

Jensen J. R., (2005), "Introductory Digital Image Processing: A Remote Sensing Perspective", 3rd Edition, Upper Saddle River: Prentice-Hall.

Jiang J., Johansen K., Tu Y. H., McCabe M. F., (2022). Multi-sensor and multi-platform consistency and interoperability between UAV, Planet CubeSat, Sentinel-2, and Landsat reflectance data. *GIScience & Remote Sensing*, 59 (1), 936-958.

Jordan C. F., (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50 (4), 663-666.

Joshi N., Baumann M., Ehammer A., Fensholt R., Grogan K., Hostert P., Waske B., (2016). A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring. *Remote Sensing*, 8 (1), 70.

Kalantar B., Mansor S. B., Halin A. A., Shafri H. Z. M., Zand M., (2017). Multiple moving object detection from UAV videos using trajectories of matched regional adjacency graphs. *IEEE Transactions on Geoscience and Remote Sensing*, 55 (9), 5198-5213.

Kalkan K., (2011), "Kentsel gelişim için potansiyel açık alanların belirlenmesinde nesne tabanlı sınıflandırma yöntemi ile transfer edilebilir kural dizisi oluşturulması", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi.

Kataoka T., Kaneko T., Okamoto H., Hata S., (2003), “Crop growth estimation system using machine vision”, In Proceedings 2003 IEEE/ASME international conference on advanced intelligent mechatronics, 1079-1083, Kobe, Japan, 20–24 July.

Kavzoglu T., Colkesen, I., (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11 (5), 352-359.

Kavzoglu T., Erdemir M. Y., Tonbul H., (2017). Classification of semiurban landscapes from very high-resolution satellite images using a regionalized multiscale segmentation approach. *Journal of Applied Remote Sensing*, 11 (3), 035016-035016.

Kavzoglu T., Mather P. M., (2003). The use of backpropagating artificial neural networks in land cover classification. *International Journal of Remote Sensing*, 24 (23), 4907-4938.

Kavzoglu T., Tonbul H., (2017), “A comparative study of segmentation quality for multi-resolution segmentation and watershed transform”, Proceedings of 8th International Conference on Recent Advances in Space Technologies (RAST’2017), Istanbul, Turkey, 19-22 June.

Kavzoglu T., Tonbul H., (2018), “Segmentation quality assessment for varying spatial resolutions of very high-resolution satellite imagery”, Eurasian GIS Congress, 1-6, Baku, Azerbaijan, 04-07 September.

Kavzoglu T., Tonbul H., Yildiz Erdemir M., Colkesen I., (2018). Dimensionality reduction and classification of hyperspectral images using object-based image analysis. *Journal of the Indian Society of Remote Sensing*, 46, 1297-1306.

Kawashima S., Nakatani M., (1998). An algorithm for estimating chlorophyll content in leaves using a video camera. *Annals of Botany*, 81 (1), 49-54.

Kerle N., Heuel S., Pfeifer N., (2008), “Real-time data collection and information generation using airborne sensors”, Taylor & Francis/Balkema: Leiden, The Netherlands.

Khoshelham K., (2009). Role of tie points in integrated sensor orientation for photogrammetric map compilation. *Photogrammetric Engineering & Remote Sensing*, 75 (3), 305-311.

Kowalska J. B., Mazurek R., Gąsiorek M., Zaleski T., (2018). Pollution indices as useful tools for the comprehensive evaluation of the degree of soil contamination—A review. *Environmental Geochemistry and Health*, 40, 2395-2420.

Kuenzer C., Ottinger M., Wegmann M., Guo H., Wang C., Zhang J., Wikelski M., (2014). Earth observation satellite sensors for biodiversity monitoring: potentials and bottlenecks. *International Journal of Remote Sensing*, 35 (18), 6599-6647.

Kulkarni A.D., Lowe B., (2016). Random forest algorithm for land cover classification. *Computer Science Faculty Publications and Presentations*, 4, 7.

Lang S., (2008), “Object-based image analysis for remote sensing applications: modeling reality–dealing with complexity”, “Object-Based Image Analysis”, Berlin, Heidelberg.

Lefebvre G., Davranche A., Willm L., Campagna J., Redmond L., Merle C., Poulin B., (2019). Introducing WIW for detecting the presence of water in wetlands with landsat and sentinel satellites. *Remote Sensing*, 11 (19), 2210.

Lelong C., Herimandimby H., (2022). Land use/land cover map of Vavatenina region (Madagascar) produced by object-based analysis of very high spatial resolution satellite images and geospatial reference data. *Data in Brief*, 44, 108517.

Li M., Ma L., Blaschke T., Cheng L., Tiede D., (2016). A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. *International Journal of Applied Earth Observation and Geoinformation*, 49, 87-98.

Li M., Zang S., Zhang B., Li S., Wu C., (2014). A review of remote sensing image classification techniques: the role of spatio-contextual information. *European Journal of Remote Sensing*, 47, 389-411

Lillesand T., Kiefer R. W., Chipman J., (2015), “Remote sensing and image interpretation”, John Wiley & Sons.

Lindberg E., Hollaus M., (2012). Comparison of methods for estimation of stem volume, stem number and basal area from airborne laser scanning data in a hemi-boreal forest. *Remote Sensing*, 4 (4), 1004-1023.

Linder W., (2013), “Digital photogrammetry: theory and applications”, Springer Science & Business Media.

Lingua A., Marenchino D., Nex F., (2009). Performance analysis of the SIFT operator for automatic feature extraction and matching in photogrammetric applications. *Sensors*, 9 (05), 3745-3766.

Liu X., Yu J., Song W., Zhao X., Wang A., (2020). Remote sensing image classification algorithm based on texture feature and extreme learning machine. *Computers, Materials and Continua*, 65 (2), 1385-1395.

Louhaichi M., Borman M. M., Johnson D. E., (2001). Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International*, 16 (1), 65-70.

Lovitt J., Rahman M. M., McDermid G. J., (2017). Assessing the value of UAV photogrammetry for characterizing terrain in complex peatlands. *Remote Sensing*, 9 (7), 715.

- Lucieer A., Jong S. M. D., Turner D., (2014). Mapping landslide displacements using Structure from Motion (SfM) and image correlation of multi-temporal UAV photography. *Progress in Physical Geography*, 38 (1), 97-116.
- Ma L., Cheng L., Li M., Liu Y., Ma X., (2015). Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 102, 14-27.
- Ma L., Fu T., Li M., (2018). Active learning for object-based image classification using predefined training objects. *International Journal of Remote Sensing*, 39 (9), 2746-2765.
- Ma M., Zhao G., He B., Li Q., Dong H., Wang S., Wang Z., (2021). XGBoost-based method for flash flood risk assessment. *Journal of Hydrology*, 598, 126382.
- Ma W., (2017), "Winter Wheat Nitrogen Nutrition Diagnosis Based on the UAV Remote Sensing", MSc thesis, Henan Polytechnic University, Jiaozuo, China.
- Mahdianpari M., Salehi B., Mohammadimanesh F., Motagh M., (2017). Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 13-31.
- Mahlein A. K., Rumpf T., Welke P., Dehne H. W., Plümer L., Steiner U., Oerke E. C., (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21-30.
- Malakouti S. M., Menhaj M. B., Suratgar A. A., (2023). The usage of 10-fold cross-validation and grid search to enhance ML methods performance in solar farm power generation prediction. *Cleaner Engineering and Technology*, 15, 100664.
- Mamaghani B., Salvaggio C., (2019). Multispectral sensor calibration and characterization for sUAS remote sensing. *Sensors*, 19 (20), 4453.
- Mancini F., Dubbini M., Gattelli M., Stecchi F., Fabbri S., Gabbianelli G., (2013). Using unmanned aerial vehicles (UAV) for high-resolution reconstruction of topography: The structure from motion approach on coastal environments. *Remote Sensing*, 5 (12), 6880-6898.
- Manfreda S., Dvorak P., Mullerova J., Herban S., Vuono P., Arranz Justel J. J., Perks M., (2019). Assessing the accuracy of digital surface models derived from optical imagery acquired with unmanned aerial systems. *Drones*, 3 (1), 15.
- Mantero P., Moser G., Serpico S. B., (2005). Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 43 (3), 559-570.

Mao W., Wang Y., Wang Y. (2003), “Real-time detection of between-row weeds using machine vision”, In 2003 ASAE Annual Meeting, American Society of Agricultural and Biological Engineers, Las Vegas, NV, USA, 27–30 July.

Mashala M. J., Dube T., Mudereri B. T., Ayisi K. K., Ramudzuli M. R., (2023). A Systematic Review on Advancements in Remote Sensing for Assessing and Monitoring Land Use and Land Cover Changes Impacts on Surface Water Resources in Semi-Arid Tropical Environments. *Remote Sensing*, 15 (16), 3926.

Mathews A. J., (2015), A practical UAV remote sensing methodology to generate multispectral orthophotos for vineyards: Estimation of spectral reflectance using compact digital cameras. *International Journal of Applied Geospatial Research (IJAGR)*, 6 (4), 65-87.

Matese A., Toscano P., Di Gennaro S. F., Genesio L., Vaccari F. P., Primicerio J., Gioli B., (2015). Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7 (3), 2971-2990.

Maxwell A. E., Warner T. A., Fang F., (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39 (9), 2784-2817.

Maxwell, T. (2005), “Object-oriented classification: Classification of pan-sharpening quickbird imagery and a fuzzy approach to improving image segmentation efficiency”, Technical Report, Geodesy and Geomatics Engineering.

Mercier G., Lennon M., (2003), “Support vector machines for hyperspectral image classification with spectral-based kernels”, 2003 IEEE International Geoscience and Remote Sensing Symposium, Toulouse, France, 21-25 July.

Merzlyak M. N., Gitelson A. A., Chivkunova O. B., Rakitin V. Y., (1999). Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum*, 106 (1), 135-141.

Mesas-Carrascosa F. J., Rumbao I. C., Berrocal J. A. B., Porrás A. G. F., (2014). Positional quality assessment of orthophotos obtained from sensors onboard multi-rotor UAV platforms. *Sensors*, 14 (12), 22394-22407.

Meyer G. E., Neto J. C., (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and electronics in agriculture*, 63 (2), 282-293.

Ming D., Li J., Wang J., Zhang M., (2015). Scale parameter selection by spatial statistics for GeOBIA: Using mean-shift based multi-scale segmentation as an example. *ISPRS Journal of Photogrammetry and Remote Sensing*, 106, 28-41.

Mo W. F., Sun H., Zhong S. Q., Huang Y. L., He L., (2007). Research on the CIWI model and its application. *Remote Sensing Information*, 5, 16-21.

Modica G., De Luca G., Messina G., Praticò S., (2021). Comparison and assessment of different object-based classifications using machine learning algorithms and UAVs multispectral imagery: A case study in a citrus orchard and an onion crop. *European Journal of Remote Sensing*, 54 (1), 431-460.

Mollick T., Azam M. G., Karim S., (2023). Geospatial-based machine learning techniques for land use and land cover mapping using a high-resolution unmanned aerial vehicle image. *Remote Sensing Applications: Society and Environment*, 29, 100859.

Mountrakis G., Im J., Ogole C., (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (3), 247-259.

Narmilan A., Gonzalez F., Salgadoe A. S. A., Powell K., (2022). Detection of white leaf disease in sugarcane using machine learning techniques over UAV multispectral images. *Drones*, 6 (9), 230.

Niederöst M., (2000), "Reliable reconstruction of buildings for digital map revision", In: International Archives of Photogrammetry and Remote Sensing, Amsterdam, 16–23 July.

Ozturk M.Y., (2022), "Novel Hybrid Classification Approach to Integrate Pixel-And Object-Based Image Analysis for Classification of Remotely Sensed Data", MSc thesis, Gebze Technical University, Kocaeli, Türkiye.

Pal M., (2005a). Random forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26 (1), 217-222.

Pal M., (2005b), "Multiclass approaches for support vector machine based land cover classification", 8th Annual International Conference MapIndia, New Delhi, India, 7-9 February.

Pal M., Mather P. M., (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86 (4), 554-565.

Park G., Park K., Song B., Lee H., (2022). Analyzing impact of types of UAV-derived images on the object-based classification of land cover in an urban area. *Drones*, 6 (3), 71.

Payero J. O., Neale C. M. U., Wright J. L., (2004). Comparison of eleven vegetation indices for estimating plant height of alfalfa and grass. *Applied Engineering in Agriculture*, 20 (3), 385-393.

Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., Grisel O., Duchesnay É., (2011). Scikit-learn: Machine learning in Python. *The Journal of Machine Learning Research*, 12, 2825-2830.

- Pelletier C., Valero S., Inglada J., Champion N., Dedieu G., (2016). Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment*, 187, 156-168.
- Peñuelas J., Isla R., Filella I., Araus J. L., (1997). Visible and near-infrared reflectance assessment of salinity effects on barley. *Crop Science*, 37 (1), 198-202.
- Piragnolo M., (2018), “Geomatics as support to remote sensing data analysis from UAV technology using GIS open source platforms”, PhD thesis, University of Padova.
- Pontoglio E., Dabove P., Grasso N., Lingua A. M., (2021). Automatic features detection in a fluvial environment through machine learning techniques based on uavs multispectral data. *Remote Sensing*, 13 (19), 3983.
- Qi J., Chehbouni A., Huete A. R., Kerr Y. H., Sorooshian S., (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48 (2), 119-126.
- Riazanoff S., Santer R., (2006), “Quality of Raster Data”, In: R. Devillers, R. Jeansoulin, Editors, “Fundamentals of Spatial Data Quality”, London, ISTE.
- Richards J. A., (2009), “Remote sensing with imaging radar”, Berlin/Heidelberg, Germany, Springer.
- Richards J.A., (2013), “Remote Sensing Digital Image Analysis: An Introduction”, 5th ed, Springer, Berlin.
- Rodriguez-Galiano V. F., Ghimire B., Rogan J., Chica-Olmo M., Rigol-Sanchez J. P., (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-104.
- Romero M., Luo Y., Su B., Fuentes S., (2018). Vineyard water status estimation using multispectral imagery from an UAV platform and machine learning algorithms for irrigation scheduling management. *Computers and Electronics in Agriculture*, 147, 109-117.
- Rondeaux G., Steven M., Baret F., (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55 (2), 95-107.
- Rouse J. W., Haas R. H., Schell J. A., Deering D. W., (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Special Publication*, 351 (1), 309.
- Rowe J. S., Barnes B. V., (1994). Geo-ecosystems and bio-ecosystems. *Bulletin of the Ecological Society of America*, 75 (1), 40-41.
- Sefercik U. G., Karakis S., Bayik C., Alkan M., Yastikli N., (2014). Contribution of normalized DSM to automatic building extraction from HR mono optical satellite imagery. *European Journal of Remote Sensing*, 47 (1), 575-591.

Sefercik U. G., Atesoglu A., (2017). Three-dimensional forest stand height map production utilizing airborne laser scanning dense point clouds and precise quality evaluation. *iForest-Biogeosciences and Forestry*, 10 (2), 491.

Sefercik U. G., Karakis S., Atalay C., Yigit I., Gokmen U., (2018). Novel fusion approach on automatic object extraction from spatial data: case study Worldview-2 and TOPO5000. *Geocarto International*, 33 (10), 1139-1154.

Sefercik U. G., Kavzoğlu T., Çölkesen I., Nazar M., Öztürk M. Y., Adali S., Salih D. İ. N. Ç., (2023). 3D positioning accuracy and land cover classification performance of multispectral RTK UAVs. *International Journal of Engineering and Geosciences*, 8 (2), 119-128.

Sefercik U. G., Nazar M., (2023). Consistency Analysis of RTK and Non-RTK UAV DSMs in Vegetated Areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.

Sertel E., Ekim B., Etehad Osgouei P., Kabadayi M. E., (2022). Land use and land cover mapping using deep learning based segmentation approaches and vhr worldview-3 images. *Remote Sensing*, 14 (18), 4558.

Settle J. J., Briggs S. A., (1987). Fast maximum likelihood classification of remotely-sensed imagery. *International Journal of Remote Sensing*, 8 (5), 723-734.

Shapiro L. G., Stockman G. C., (2001), "Computer Vision", 1th Edition Prentice Hall, Englewood Cliffs.

Shukla A., Jain K., (2020). Automatic extraction of urban land information from unmanned aerial vehicle (UAV) data. *Earth Science Informatics*, 13 (4), 1225-1236.

Sigdel G. P., (2021), "Informal settlement segmentation using VHR RGB and height information from UAV imagery: A case study of Nepal", MSc thesis, Jaume I University, Spain.

Simic Milas A., Romanko M., Reil P., Abeyasinghe T., Marambe A., (2018). The importance of leaf area index in mapping chlorophyll content of corn under different agricultural treatments using UAV images. *International Journal of Remote Sensing*, 39 (15-16), 5415-5431.

Smith G. M., Milton E. J., (1999). The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of Remote Sensing*, 20 (13), 2653-2662.

Sims D. A., Gamon J. A., (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81 (2-3), 337-354.

Song M., Civco D. L., Hurd J. D., (2005). A competitive pixel-object approach for land cover classification. *International Journal of Remote Sensing*, 26 (22), 4981-4997.

Sotille M. E., Bremer U. F., Vieira G., Velho L. F., Petsch C., Auger J. D., Simões J. C., (2022). UAV-based classification of maritime Antarctic vegetation types using GEOBIA and random forest. *Ecological Informatics*, 71, 101768.

Steiner D., (1965). Use of air photographs for interpreting and mapping rural land use in the United States. *Photogrammetria*, 20 (2), 65-80.

Straub B. M., Gerke M., Koch A., (2001), “Automatic extraction of trees and buildings from image and height data in an urban environment”, International Workshop on Geo-Spatial Knowledge Processing for Natural Resource Management, Varese, Italy, 28-29 June.

Su J., Yi D., Coombes M., Liu C., Zhai X., McDonald-Maier K., Chen W. H., (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 192, 106621.

Szostak M., Wezyk P., Tompalski P., (2014). Aerial orthophoto and airborne laser scanning as monitoring tools for land cover dynamics: A case study from the Milicz Forest District (Poland). *Pure and Applied Geophysics*, 171, 857-866.

Thanh Noi P., Kappas M., (2017). Comparison of random forest, k-nearest neighbor, and support vector machine classifiers for land cover classification using Sentinel-2 imagery. *Sensors*, 18 (1), 18.

Tian J., Chen D. M., (2007). Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing*, 28 (20), 4625-4644.

Tinkham W. T., Swayze N. C., (2021). Influence of Agisoft Metashape parameters on UAS structure from motion individual tree detection from canopy height models. *Forests*, 12 (2), 250.

Tonbul, H., (2021), “Nesne-Tabanlı Sınıflandırmada Doğal Arazi Örtüsü Sınırlarını Esas Alan Bölge Tabanlı Bölütleme (Segmentasyon) Algoritmasının Optimizasyonu”, Doktora Tezi, Gebze teknik Üniversitesi.

Townshend J., Justice C., Li W., Gurney C., McManus J., (1991). Global land cover classification by remote sensing: present capabilities and future possibilities. *Remote Sensing of Environment*, 35 (2-3), 243-255.

Tucker C. J., (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8 (2), 127-150.

Turner D., Lucieer A., Watson C., (2012), An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (UAV) imagery, based on structure from motion (SfM) point clouds. *Remote Sensing*, 4 (5), 1392-1410.

Ullman S., (1979). The interpretation of structure from motion. Proceedings of the Royal Society of London. *Series B. Biological Sciences*, 203 (1153), 405-426.

Van Blyenburgh P., (1999). UAVs: an overview. *Air and Space Europe*, 1 (5), 43-47.

Vanhuyse S., Grippa T., Lennert M., Wolff E., Idrissa M., (2017), "Contribution of nDSM derived from VHR stereo imagery to urban land-cover mapping in Sub-Saharan Africa", In 2017 Joint Urban Remote Sensing Event (JURSE), Dubai, United Arab Emirates, 6–8 March.

V. Vapnik, (1998), "Statistical Learning Theory Wiley-Interscience", Hoboken, NJ, USA.

Ventura D, Bonifazi A, Gravina MF, Belluscio A, Ardizzone G., (2018). Mapping and classification of ecologically sensitive marine habitats using unmanned aerial vehicle (UAV) imagery and object-based image analysis (OBIA). *Remote Sensing*, 10 (9), 1331.

Wang C., (2021). At-sensor radiometric correction of a multispectral camera (RedEdge) for sUAS vegetation mapping. *Sensors*, 21 (24), 8224.

Watts J. D., Powell S. L., Lawrence R. L., Hilker T., (2011). Improved classification of conservation tillage adoption using high temporal and synthetic satellite imagery. *Remote Sensing of Environment*, 115 (1), 66-75.

Westoby M. J., Brasington J., Glasser N. F., Hambrey M. J., Reynolds J. M., (2012). 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. *Geomorphology*, 179, 300-314.

Wijesingha J., (2016), "Geometric quality assessment of multi-rotor unmanned aerial vehicle borne remote sensing products for precision agriculture", MSc thesis, Lund University, Sweden.

Willhauck G., Schneider T., De Kok R., Ammer U., (2000), "Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos", XIX ISPRS congress, Amsterdam.

Witharana C., Civco D. L., (2014). Optimizing multi-resolution segmentation scale using empirical methods: Exploring the sensitivity of the supervised discrepancy measure Euclidean distance 2 (ED2). *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 108-121.

Woebbecke D. M., Meyer G. E., Von Bargen K., Mortensen D. A., (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38 (1), 259-269.

Wu C., Wu J., Luo Y., Zhang L., DeGloria S. D., (2009). Spatial prediction of soil organic matter content using cokriging with remotely sensed data. *Soil Science Society of America Journal*, 73 (4), 1202-1208.

- Yang B., Tong S. T. Y., Fan R., (2021). Using high resolution images from UAV and satellite remote sensing for best management practice analyses. *Journal of Environmental Informatics*, 37 (1), 79.
- Yang Z., Willis P., Mueller R., (2008), “Impact of band-ratio enhanced AWIFS image to crop classification accuracy”, In Proceedings of the Pecora 17 Remote Sensing Symposium, Denver, CO, Canada, 18–20 November 2008.
- Yao X., Fu X., Zong, C., (2022). Short-term load forecasting method based on feature preference strategy and LightGBM-XGboost. *IEEE Access*, 10, 75257-75268.
- Yao H., Qin R., Chen X., (2019). Unmanned aerial vehicle for remote sensing applications—A review. *Remote Sensing*, 11 (12), 1443.
- Yu Q, Gong P, Clinton N, Biging G, Kelly M, Schirokauer D., (2006). Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. *Photogrammetric Engineering & Remote Sensing*, 72 (7), 799.
- Yuan Y., Hu X., (2016), “Random forest and objected-based classification for forest pest extraction from UAV aerial imagery”, 23rd International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences Congress, Prague, Czech Republic, 12–19 July 2016.
- Zafari A., Zurita-Milla R., Izquierdo-Verdiguier E., (2019). Evaluating the performance of a random forest kernel for land cover classification. *Remote Sensing*, 11 (5), 575.
- Zhang X., Chen G., Wang W., Wang Q., Dai F., (2017). Object-based land-cover supervised classification for very-high-resolution UAV images using stacked denoising autoencoders. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10 (7), 3373-3385.
- Zhang S., Li X., Ba Y., Lyu X., Zhang M., Li M., (2022). Banana Fusarium Wilt Disease Detection by Supervised and Unsupervised Methods from UAV-Based Multispectral Imagery. *Remote Sensing*, 14 (5), 1231.
- Zhang J., Xu S., Zhao Y., Sun J., Xu S., Zhang X., (2023). Aerial orthoimage generation for UAV remote sensing. *Information Fusion*, 89, 91-120.
- Zhou R., Yang C., Li E., Cai X., Yang J., Xia Y., (2021). Object-based wetland vegetation classification using multi-feature selection of unoccupied aerial vehicle RGB imagery. *Remote Sensing*, 13 (23), 4910.
- Zhu H., Basir O., (2005). An adaptive fuzzy evidential nearest neighbor formulation for classifying remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 43 (8), 1874-1889.

Zisi T., Alexandridis T. K., Kaplanis S., Navrozidis I., Tamouridou A. A., Lagopodi A., Polychronos V., (2018). Incorporating surface elevation information in UAV multispectral images for mapping weed patches. *Journal of Imaging*, 4 (11), 132.



## ÖZGEÇMİŞ

İlyas Aydın, 2015 yılında Selçuk Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Harita Mühendisliği Anabilim Dalı'nda başladığı lisans eğitimini 2019 yılında başarıyla tamamladı. 2022 yılında Gebze Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Jeodezi ve Coğrafi Bilgi Teknolojileri bölümünde yüksek lisans eğitimine başladı. 2022 yılında Gebze Teknik Üniversitesi Harita Mühendisliği bölümünde Araştırma Görevlisi olarak göreve başladı ve aktif iş hayatına bu kurumda devam etmektedir.



## TEZ METNİNDEN TÜRETİLEN YAYINLAR/SUNUMLAR

Aydın I., Sefercik U. G., (2023), “LULC mapping accuracy enhancement through multispectral UAV imagery with nDSM integration”, 8th Advanced Engineering Days, Mersin, Türkiye, 8 December.



## EKLER

**Tablo-A.1: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	<b>1099368</b>	67077	541	625	2402	321	1231	0	1	0	14624	1186190
	Y	287483	<b>1556093</b>	131	1028	1656	48	1205	86	9	0	7054	1854793
	G	46880	571	<b>473773</b>	3706	2	55	59	25	13479	23204	5020	566774
	S	2617	19	313	<b>131012</b>	0	0	5	0	0	0	460	134426
	BY	1742	467	27	21	<b>45189</b>	3	71	0	0	0	7	47527
	Ç	84	217	172	22	0	<b>975541</b>	32	32666	15334	4927	14	1029009
	T	28521	25122	262	1892	90	336	<b>244350</b>	18744	129	22	3651	323119
	SBÖ	2068	2865	554	613	6	123447	13324	<b>355391</b>	889	623	378	500158
	GYA	927	334	62	159	9	14536	27	463	<b>536797</b>	2974	35	556323
	İYA	44	30	5060	572	2	8699	6	726	29309	<b>409253</b>	90	453791
	KÇ	6569	992	233	68	0	0	76	0	0	0	<b>983345</b>	991283
	<b>Toplam</b>		1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678
<b>PA [%]</b>		74.5	94.1	98.5	93.8	91.6	86.9	93.8	87.1	90.1	92.8	96.9	<b>OA [%]</b>
<b>UA [%]</b>		92.7	83.9	83.6	97.5	95.1	94.8	75.6	71.1	96.5	90.2	99.2	<b>89.1</b>

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.2: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V2 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	<b>1073015</b>	29906	432	767	2091	320	1070	0	1	0	14957	1122559
	Y	303932	<b>1593965</b>	109	679	1831	47	1518	86	9	0	6209	1908385
	G	51209	812	<b>474453</b>	3698	14	119	48	33	14333	26618	5748	577085
	S	2121	13	210	<b>131310</b>	0	0	0	0	0	0	270	133924
	BY	1602	327	27	21	<b>45262</b>	12	68	0	0	0	7	47326
	Ç	53	213	149	33	0	<b>988282</b>	56	35340	11730	990	36	1036882
	T	35950	23894	252	1936	141	351	<b>245275</b>	18592	85	23	4327	330826
	SBÖ	1416	3109	557	588	6	110495	12261	<b>353502</b>	931	581	321	483767
	GYA	823	224	60	115	9	16669	14	98	<b>543411</b>	3644	23	565090
	İYA	45	26	4681	493	2	6691	0	450	25447	<b>409147</b>	75	447057
	KÇ	6137	1298	198	78	0	0	76	0	0	0	<b>982705</b>	990492
	<b>Toplam</b>		1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678
<b>PA [%]</b>		72.7	96.4	98.6	94.0	91.7	88.0	94.2	86.6	91.2	92.8	96.8	<b>OA [%]</b>
<b>UA [%]</b>		95.6	83.5	82.2	98.0	95.6	95.3	74.1	73.1	96.2	91.5	99.2	<b>89.5</b>

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.3: 5-BANTLI ORTOMOZAIKDEN ÜRETİLEN V3 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1367987	4822	315	529	209	102	436	0	1	0	19987	1394388
	Y	29283	1618073	140	574	4164	73	1783	86	9	0	2290	1656475
	G	45249	1530	475555	3442	18	248	95	41	12649	24531	4471	567829
	S	2093	13	174	132138	0	0	0	0	0	0	339	134757
	BY	1579	342	27	21	44866	16	158	0	0	0	7	47016
	Ç	10	225	346	46	0	1012915	53	36342	5496	127	18	1055578
	T	20878	24570	222	2258	82	415	245560	18417	65	23	3168	315658
	SBÖ	1352	3109	562	386	6	107632	12230	353079	911	531	308	480106
	GYA	757	201	57	97	9	1197	17	28	551351	4206	30	557950
	İYA	39	26	3509	149	2	388	0	108	25465	411585	103	441374
	KÇ	7076	876	221	78	0	0	54	0	0	0	983957	992262
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
PA [%]	92.7	97.8	98.8	94.6	90.9	90.2	94.3	86.5	92.5	93.3	97.0	OA [%]	
UA [%]	98.1	97.7	83.7	98.1	95.4	96.0	77.8	73.5	98.8	93.3	99.2	94.2	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.4: 5-BANTLI ORTOMOZAIKDEN ÜRETİLEN V4 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1369763	4772	324	603	186	102	685	0	1	0	20165	1396601
	Y	30900	1617674	125	826	3885	65	1830	86	9	0	1955	1657355
	G	42794	2039	475647	3132	18	270	72	43	13440	23073	4505	565033
	S	2418	13	220	132456	0	0	0	0	0	0	387	135494
	BY	1381	415	27	21	45168	16	138	0	0	0	7	47173
	Ç	13	254	608	64	0	1002269	53	35704	6115	126	14	1045220
	T	20176	24739	221	1585	82	425	244599	19025	105	23	3322	314302
	SBÖ	1458	2913	651	622	6	118507	12936	353114	905	517	301	491930
	GYA	789	188	57	101	9	991	18	31	548760	5247	32	556223
	İYA	48	28	3050	230	2	341	0	98	26612	412017	105	442531
	KÇ	6563	752	198	78	0	0	55	0	0	0	983885	991531
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
PA [%]	92.8	97.8	98.9	94.8	91.5	89.3	93.9	86.5	92.1	93.4	97.0	OA [%]	
UA [%]	98.1	97.6	84.2	97.8	95.7	95.9	77.8	71.8	98.7	93.1	99.2	94.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.5: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1123179	78906	508	900	3789	188	1149	0	9	0	12411	1221039
	Y	267961	1548675	204	661	700	34	746	0	26	0	7824	1826831
	G	47612	649	473183	5897	4	196	85	21	12909	14925	5022	560503
	S	1341	10	30	129047	0	0	0	0	0	0	60	130488
	BY	1050	588	12	6	44710	7	9	0	4	0	2	46388
	Ç	8	163	156	11	0	991522	51	34499	11368	1437	10	1039225
	T	26180	19133	120	2089	156	270	246719	15764	95	6	2932	313464
	SBÖ	1977	3487	955	579	4	106580	11567	357284	1322	1233	397	485385
	GYA	1359	817	188	173	18	16298	31	15	557014	2121	57	578091
	İYA	37	47	5609	299	5	7812	13	494	13430	421263	65	449074
	KÇ	5539	1179	273	61	0	0	123	0	0	0	985920	993095
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
PA [%]	76.1	93.7	98.3	92.4	90.5	88.3	94.7	87.6	93.4	95.5	97.2	OA [%]	
UA [%]	92.0	84.8	84.4	98.9	96.4	95.4	78.7	73.6	96.4	93.8	99.3	90.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.6: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V2 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1097881	27467	594	1255	2891	194	1040	0	2	0	14741	1146065
	Y	300633	1597937	207	576	1803	28	656	0	27	0	6999	1908866
	G	46815	616	473832	5250	4	202	95	42	12157	15695	4860	559568
	S	744	0	0	129263	0	0	0	0	0	0	60	130067
	BY	1013	419	12	14	44534	7	82	0	4	0	2	46087
	Ç	24	217	126	39	0	987497	61	32712	7127	430	23	1028256
	T	19647	21742	127	1924	127	286	247429	16136	100	6	1656	309180
	SBÖ	1491	3991	1014	485	7	107851	11039	358704	1514	1168	383	487647
	GYA	1234	308	194	161	15	20801	17	175	563313	2080	34	588332
	İYA	36	24	4918	685	5	6041	17	308	11933	421606	74	445647
	KÇ	6725	933	214	71	0	0	57	0	0	0	985868	993868
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
PA [%]	74.4	96.6	98.5	92.5	90.2	87.9	95.0	87.9	94.5	95.6	97.2	OA [%]	
UA [%]	95.8	83.7	84.7	99.4	96.6	96.0	80.0	73.6	95.7	94.6	99.2	90.4	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.7: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V3 VERİ SETİ VE RF ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1382524	6674	382	1073	184	0	570	0	32	0	19246	1410685
	Y	22991	1614103	273	997	4863	229	1091	0	18	0	2012	1646577
	G	43225	903	475021	5792	4	184	91	68	11631	14746	5359	557024
	S	636	20	10	128892	0	0	0	0	0	0	3	129561
	BY	1502	475	12	6	44146	16	88	0	1	0	2	46248
	Ç	316	228	366	481	0	1006124	76	34485	3646	229	30	1045981
	T	16655	23050	216	1496	162	277	247438	16149	94	6	1517	307060
	SBÖ	1524	4538	674	622	7	110907	11034	357186	1496	718	345	489051
	GYA	964	256	160	119	15	1896	9	15	566375	3247	46	573102
	İYA	33	13	3876	183	5	3274	10	174	12884	422039	76	442567
	KÇ	5873	3394	248	62	0	0	86	0	0	0	986064	995727
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
	PA [%]	93.7	97.6	98.7	92.2	89.4	89.6	95.0	87.5	95.0	95.7	97.2	OA [%]
UA [%]	98.0	98.0	85.3	99.5	95.5	96.2	80.6	73.0	98.8	95.4	99.0	94.6	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.8: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1011800	319327	242	727	1826	196	1677	53	3	0	16265	1352116
	Y	335681	1306954	39	133	97	47	1693	0	7	0	2321	1646972
	G	63189	2010	476595	3736	54	336	113	80	14039	32392	6889	599433
	S	5525	14	68	132319	0	0	0	0	48	0	1131	139105
	BY	31749	976	28	14	47256	9	1387	0	2	0	1936	83357
	Ç	224	287	130	37	0	1021166	36	41514	22514	10340	100	1096348
	T	12998	21103	76	62	109	792	231623	13856	137	3	795	281554
	SBÖ	4481	1780	435	397	0	77032	22017	351947	1563	1530	1946	463128
	GYA	343	330	181	123	12	7110	15	421	541315	4050	49	553949
	İYA	36	11	3041	163	2	16298	0	230	16319	392688	29	428817
	KÇ	10277	995	293	2007	0	0	1825	0	0	0	983217	998614
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
	PA [%]	68.5	79.0	99.1	94.7	95.7	90.9	89.0	86.2	90.8	89.0	96.9	OA [%]
UA [%]	74.8	79.4	79.5	95.1	56.7	93.1	82.3	76.0	97.7	91.6	98.5	85.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.9: 5-BANTLI ORTOMOZAİKDEN ÜRETİLEN V2 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	<b>1029639</b>	237945	253	701	2340	85	1509	0	3	0	15831	1288306
	Y	336203	<b>1381457</b>	25	1557	262	133	5635	53	11	0	1773	1727109
	G	71164	2915	<b>475966</b>	4106	42	302	125	110	21468	31316	7136	614650
	S	58	5	12	<b>131686</b>	0	0	0	0	50	0	1020	132831
	BY	6969	902	13	14	<b>46570</b>	9	1327	0	2	0	492	56298
	Ç	331	615	103	46	9	<b>970566</b>	96	42069	35594	3579	40	1053048
	T	17583	26202	110	296	128	568	<b>229135</b>	21141	378	63	1138	296742
	SBÖ	3170	1679	391	161	0	130471	18895	<b>344448</b>	1902	1419	1583	504119
	GYA	214	96	222	80	3	17503	18	191	<b>519094</b>	4414	62	541897
	İYA	16	15	3671	195	2	3349	0	89	17445	<b>400212</b>	34	425028
	KÇ	10956	1956	362	876	0	0	3646	0	0	0	<b>985569</b>	1003365
	Toplam		1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678
PA [%]		69.7	83.5	98.9	94.3	94.4	86.4	88.0	84.4	87.1	90.8	97.1	<b>OA [%]</b>
UA [%]		79.9	80.0	77.4	99.1	82.7	92.2	77.2	68.3	95.8	94.2	98.2	<b>85.2</b>

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A. 10: 5-BANTLI ORTOMOZAİKDEN ÜRETİLEN V3 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	<b>1319454</b>	19787	222	1018	1961	63	345	0	1	0	18616	1361467
	Y	46251	<b>1601476</b>	51	1184	645	176	6713	101	13	0	723	1657333
	G	70569	2962	<b>475988</b>	4266	42	300	125	80	19406	30180	7129	611047
	S	58	5	12	<b>131686</b>	0	0	0	0	50	0	1020	132831
	BY	6977	964	13	14	<b>46556</b>	9	1410	0	8	0	492	56443
	Ç	206	608	193	108	9	<b>1007824</b>	87	42090	12331	664	21	1064141
	T	20442	23862	70	265	134	566	<b>232188</b>	21211	347	46	1748	300879
	SBÖ	1066	1984	428	147	0	108815	15850	<b>344355</b>	1421	1371	984	476421
	GYA	421	149	163	65	3	3795	22	162	<b>545285</b>	3711	90	553866
	İYA	30	18	3625	92	2	1438	0	102	17085	<b>405031</b>	47	427470
	KÇ	10829	1972	363	873	4	0	3646	0	0	0	<b>983808</b>	1001495
	Toplam		1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678
PA [%]		89.4	96.8	98.9	94.3	94.3	89.7	89.2	84.4	91.5	91.8	97.0	<b>OA [%]</b>
UA [%]		96.9	96.6	77.9	99.1	82.5	94.7	77.2	72.3	98.5	94.8	98.2	<b>92.8</b>

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.11: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V4 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1324897	21901	262	1247	1946	63	446	0	1	0	18706	1369469
	Y	41037	1598638	16	994	652	196	6311	53	11	0	511	1648419
	G	70785	2937	476002	4126	42	302	125	110	22043	31333	7278	615083
	S	58	5	12	131686	0	0	0	0	50	0	1020	132831
	BY	7015	949	13	29	46581	9	1526	0	2	0	492	56616
	Ç	185	471	177	78	9	1019182	80	42942	13820	166	7	1077117
	T	20027	24563	70	302	117	467	230616	15979	365	23	1728	294257
	SBÖ	1014	2137	444	118	0	97472	17405	348531	1410	1434	980	470945
	GYA	412	183	183	48	3	4031	27	423	533527	6175	118	545130
	İYA	41	15	3586	217	2	1264	0	63	24718	401872	20	431798
	KÇ	10832	1988	363	873	4	0	3850	0	0	0	983818	1001728
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
	PA [%]	89.7	96.7	98.9	94.3	94.4	90.8	88.6	85.4	89.5	91.1	97.0	OA [%]
UA [%]	96.7	97.0	77.4	99.1	82.3	94.6	78.4	74.0	97.9	93.1	98.2	92.8	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.12: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1015103	278864	558	753	2167	14	788	0	2	0	18284	1316533
	Y	343833	1345286	172	1037	484	187	507	0	27	0	4322	1695855
	G	51165	784	472027	3312	30	415	186	105	18121	13415	6609	566169
	S	305	0	898	133345	0	0	0	0	39	0	1107	135694
	BY	41436	795	14	20	46544	12	890	0	15	0	2160	91886
	Ç	166	182	62	6	0	1004965	148	38182	33069	2538	83	1079401
	T	16223	25235	77	153	147	722	237653	19293	138	7	2435	302083
	SBÖ	945	1726	235	44	4	99794	20214	349971	2004	536	358	475831
	GYA	587	488	506	188	5	5430	22	96	530784	8936	65	547107
	İYA	26	30	6487	131	5	11368	4	430	11975	415553	25	446034
	KÇ	6454	264	202	734	0	0	81	0	3	0	979252	986990
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
	PA [%]	68.8	81.4	98.1	95.4	94.2	89.5	91.2	85.8	89.0	94.2	96.5	OA [%]
UA [%]	77.1	79.3	83.4	98.3	50.7	93.1	78.7	73.5	97.0	93.2	99.2	85.4	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.13: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V2 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1087258	237757	504	2066	2122	167	667	0	7	0	16283	1346831
	Y	284680	1386733	130	803	842	304	2464	0	29	0	4126	1680111
	G	50498	1093	468186	5270	42	227	436	90	22600	21957	9510	579909
	S	838	0	424	129912	0	0	0	0	14	0	763	131951
	BY	19600	622	9	20	46173	12	893	0	8	0	1548	68885
	Ç	197	159	81	5	0	991734	59	34858	17619	3876	29	1048617
	T	18607	22681	176	149	195	394	238455	35409	170	70	3400	319706
	SBÖ	1440	2827	159	631	7	109077	16374	337014	3039	440	575	471583
	GYA	1561	417	1017	58	0	7412	90	594	546943	17230	88	575410
	İYA	57	3	10306	172	5	13580	16	112	5748	397412	53	427464
	KÇ	11507	1362	246	637	0	0	1039	0	0	0	978325	993116
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
PA [%]	73.7	83.9	97.3	93.0	93.5	88.3	91.5	82.6	91.7	90.1	96.4	OA [%]	
UA [%]	80.7	82.5	80.7	98.5	67.0	94.6	74.6	71.5	95.1	93.0	98.5	86.4	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.14: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V3 VERİ SETİ VE SVM ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1316225	56467	50151	838	19600	11	20071	654	1242	55	10929	1476243
	Y	35059	1589394	1091	0	622	151	22335	3192	425	17	1368	1653654
	G	527	105	469378	424	9	82	196	141	644	9486	246	481238
	S	1157	1716	5189	129921	20	4	170	500	59	160	827	139723
	BY	1569	1381	42	0	46173	0	195	21	0	5	0	49386
	Ç	130	328	216	0	12	992527	543	113747	2673	12731	0	1122907
	T	441	2714	437	0	893	34	236280	18536	110	10	1038	260493
	SBÖ	0	0	95	0	0	37384	29487	340810	198	103	0	408077
	GYA	7	29	22464	14	8	11222	200	2763	553666	5804	0	596177
	İYA	0	0	23525	0	0	2441	125	350	10623	403921	0	440985
	KÇ	18295	2135	9510	763	1548	15	3540	438	112	42	978302	1014700
	Toplam	1373410	1654269	582098	131960	68885	1043871	313142	481152	569752	432334	992710	7643583
PA [%]	95.8	96.1	80.6	98.5	67.0	95.1	75.5	70.8	97.2	93.4	98.5	OA [%]	
UA [%]	89.2	96.1	97.5	93.0	93.5	88.4	90.7	83.5	92.9	91.6	96.4	92.3	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.15: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1164853	100048	429	135	5435	235	2033	0	2	0	21090	1294260
	Y	215924	1522889	153	654	496	57	343	86	7	0	6960	1747569
	G	50287	2023	475395	6083	144	278	119	56	5548	30179	11170	581282
	S	7742	24	20	131038	0	0	0	0	13	0	25	138862
	BY	1240	930	71	8	43153	0	235	0	41	0	20	45698
	Ç	206	200	115	11	0	993968	6	29676	14569	1834	13	1040598
	T	30740	21082	181	216	111	295	241720	16618	59	23	11781	322826
	SBÖ	1374	5565	807	1061	2	111726	15008	360193	1022	662	1610	499030
	GYA	618	574	194	134	13	10225	35	979	550511	3065	124	566472
	İYA	96	28	3581	279	2	6202	6	493	24175	405240	119	440221
	KÇ	3223	424	182	99	0	0	881	0	0	0	961766	966575
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
PA [%]	78.9	92.1	98.8	93.8	87.4	88.5	92.8	88.3	92.4	91.9	94.8	OA [%]	
UA [%]	90.0	87.1	81.8	94.4	94.4	95.5	74.9	72.2	92.1	99.5	89.7		

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A. 16: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V2 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	4605021	171050	2159	903	16033	969	5484	0	0	0	77904	4879523
	Y	918444	6329708	434	2626	6842	190	981	345	61	0	28262	7287893
	G	201986	5531	1895935	22435	64	1002	372	131	22178	112646	61980	2324260
	S	19820	169	29	522483	0	0	0	0	0	0	120	542621
	BY	6508	2192	159	276	173850	3	1409	0	127	0	40	184564
	Ç	334	1358	464	70	0	4021042	108	125659	65905	5665	50	4220655
	T	130570	82852	1083	1426	700	1195	977644	62404	392	95	37239	1295600
	SBÖ	6127	17891	4007	4473	23	417944	55514	1441451	3984	3558	6047	1961019
	GYA	3044	1202	415	511	48	45217	48	437	2178837	11045	157	2240961
	İYA	403	82	19183	3171	11	4456	27	1720	112740	1630941	349	1773083
	KÇ	12825	2875	686	419	2	0	126	0	0	0	3846567	3863500
	Toplam	5905082	6614910	1924554	558793	197573	4492018	1041713	1632147	2384224	1763950	4058715	3.1E+07
PA [%]	78.0	95.7	98.5	93.5	88.0	89.5	93.8	88.3	91.4	92.5	94.8	OA [%]	
UA [%]	94.4	86.9	81.6	96.3	94.2	95.3	75.5	73.5	97.2	92.0	99.6	90.4	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.17: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V3 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1362360	3641	980	215	110	0	225	0	0	0	26910	1394441
	Y	32617	1622295	138	439	4771	167	791	86	9	0	1697	1663010
	G	36859	2291	475302	5993	18	446	128	56	4631	28652	10101	564477
	S	6133	24	5	130962	0	0	0	0	13	0	355	137492
	BY	1739	464	32	31	44268	0	820	0	31	0	11	47396
	Ç	114	430	332	62	9	1009303	53	29469	6354	168	6	1046300
	T	30150	19248	299	367	171	293	245232	16532	80	23	10235	322630
	SBÖ	1175	4806	1307	1303	5	111185	13095	361845	844	547	821	496933
	GYA	1712	260	93	92	0	1251	20	37	559122	3479	489	566555
	İYA	51	18	2399	155	2	341	0	76	24863	408134	163	436202
	KÇ	3393	310	241	99	2	0	22	0	0	0	963890	967957
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
PA [%]	92.3	98.1	98.8	93.7	89.7	94.2	88.7	93.8	92.5	95.0	95.0	OA [%]	
UA [%]	97.7	97.6	84.2	95.3	93.4	96.5	76.0	72.8	98.7	93.6	99.6	94.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.18: 5-BANTLI ORTOMOZAIK DEN ÜRETİLEN V4 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1365663	3507	1020	394	63	0	294	0	0	0	31720	1402661
	Y	31434	1622569	150	774	4509	168	1070	86	9	0	1653	1662422
	G	36471	2010	475216	5873	18	400	134	56	5551	28099	9562	563390
	S	6997	24	2	130292	0	0	0	0	13	0	5	137333
	BY	1296	540	41	61	44557	0	798	0	41	0	89	47423
	Ç	374	719	299	40	9	1012162	46	31432	6280	126	5	1051492
	T	27801	18633	288	532	157	253	244374	16214	84	23	6226	314585
	SBÖ	1222	5201	1237	1386	6	107641	13619	360212	855	558	465	492402
	GYA	1604	259	92	63	0	1989	20	22	556534	4065	931	565579
	İYA	46	15	2529	204	2	373	0	79	26580	408132	143	438103
	KÇ	3395	310	254	99	35	0	31	0	0	0	963879	968003
	Toplam	1476303	1653787	481128	139718	49356	1122986	260386	408101	595947	441003	1014678	7643393
PA [%]	92.5	98.1	98.8	93.3	90.3	90.1	93.9	88.3	93.4	92.5	95.0	OA [%]	
UA [%]	97.4	97.6	84.3	94.9	94.0	96.3	77.7	73.2	98.4	93.2	99.6	94.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.19: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V1 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1151306	88884	566	119	3802	161	3081	0	3	0	15199	1263121
	Y	249054	1538414	201	969	1134	185	440	0	27	0	7492	1797916
	G	37321	1131	474653	6453	6	57	81	65	6533	17795	7425	551520
	S	8353	0	25	130097	0	0	0	0	0	0	114	138589
	BY	2287	1488	143	510	44234	1	142	0	4	0	576	49385
	Ç	177	146	97	0	0	1017847	46	31696	10427	629	0	1061065
	T	22144	16554	241	0	147	203	244321	17461	94	12	6452	307629
	SBÖ	1139	5017	963	966	11	82577	12261	357855	1455	746	658	463648
	GYA	870	1067	174	182	5	17739	50	640	561142	2364	127	584360
	İYA	27	48	3882	345	5	4137	10	360	16492	419439	51	444796
	KÇ	3565	905	293	82	42	0	61	0	0	0	976606	981554
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
	PA [%]	78.0	93.0	98.6	93.1	89.6	90.6	93.8	87.7	94.1	95.1	96.2	OA [%]
UA [%]	91.1	85.6	86.1	93.9	89.6	95.9	79.4	77.2	96.0	94.3	99.5	90.5	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A. 20: 6-BANTLI ORTOMOZAIK DEN ÜRETİLEN V2 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	1128260	50522	381	257	3532	53	3058	0	0	0	17732	1203795
	Y	261939	1576139	170	854	1630	33	513	0	31	0	6502	1847811
	G	51232	1364	475163	6633	51	495	98	68	6512	18650	6680	566946
	S	2633	0	1	129512	0	0	0	0	0	0	1173	133319
	BY	1841	543	103	240	44021	0	223	0	1	0	173	47145
	Ç	3	197	101	5	0	1016322	44	32106	8621	1042	1	1058442
	T	23159	15651	260	0	127	342	243548	15833	96	6	4690	303712
	SBÖ	2225	7530	687	1737	7	85446	12926	359417	1430	607	389	472401
	GYA	1843	681	143	131	13	18208	27	242	566842	2026	167	590323
	İYA	90	48	3945	272	5	2008	10	411	12644	418654	66	438153
	KÇ	3018	979	284	82	0	0	46	0	0	0	977127	981536
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	7643583
	PA [%]	76.4	95.3	98.7	92.7	89.1	90.5	93.5	88.1	95.1	94.9	96.3	OA [%]
UA [%]	93.7	85.3	83.8	97.1	93.4	96.0	80.2	76.1	96.0	95.5	99.6	91.0	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.

**Tablo-A.21: 6-BANTLI ORTOMOZAİKDEN ÜRETİLEN V3 VERİ SETİ VE XGBOOST ALGORİTMASI İLE GERÇEKLEŞTİRİLEN SINIFLANDIRMA SONUCUNDAKİ HATA MATRİSİ.**

		Referans (piksel)											
		BÇ	Y	G	S	BY	Ç	T	SBÖ	GYA	İYA	KÇ	Toplam
Sınıflandırma	BÇ	<b>1372508</b>	4189	438	738	0	0	814	0	12	0	18215	1396914
	Y	23308	<b>1624286</b>	298	766	4433	228	1800	19	16	0	839	1655993
	G	40879	1516	<b>476036</b>	6754	30	314	103	77	5921	18507	7421	557558
	S	3394	0	1	<b>129432</b>	0	0	5	0	16	0	3773	136621
	BY	4396	1007	26	378	<b>44779</b>	7	480	0	1	0	826	51900
	Ç	7	205	169	13	0	<b>1019127</b>	59	33719	3251	227	10	1056787
	T	25003	15161	306	122	123	312	<b>244526</b>	15057	86	12	7191	307899
	SBÖ	1059	6711	931	1081	16	100167	12664	<b>358843</b>	1977	582	293	484324
	GYA	2463	200	147	106	0	1342	9	261	<b>570505</b>	3216	170	578419
	İYA	91	21	2647	265	5	1410	10	101	14392	<b>418441</b>	89	437472
	KÇ	3135	358	239	68	0	0	23	0	0	0	<b>975873</b>	979696
	Toplam	1476243	1653654	481238	139723	49386	1122907	260493	408077	596177	440985	1014700	<b>7643583</b>
	PA [%]	93.0	98.2	98.9	92.6	90.7	90.8	93.9	87.9	95.7	94.9	96.2	<b>OA [%]</b>
UA [%]	98.3	98.1	85.4	94.7	86.3	96.4	79.4	74.1	98.6	95.6	99.6	<b>94.7</b>	

BÇ, Beton çatı; Y, Yol; G, Gölge; S, Su; BY, Bisiklet yolu; Ç, Çimen; T, Toprak; SBÖ, Seyrek bitki örtüsü; GYA, Geniş yapraklı ağaç; İYA, İğne yapraklı ağaç; KÇ, Kırmızı çatı.