



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



İNSANSIZ HAVA ARACI İLE
FOTOGRAMETRİK TEMELLİ GÖRÜNTÜ
ALIMI VE UÇUŞ OPTİMİZASYONU

Hasan Bilgehan MAKİNECİ

DOKTORA TEZİ

Harita Mühendisliği Anabilim Dalı

Aralık-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hasan Bilgehan MAKİNECİ tarafından hazırlanan “İNSANSIZ HAVA ARACI İLE FOTOGRAMETRİK TEMELLİ GÖRÜNTÜ ALIMI VE UÇUŞ OPTİMİZASYONU” adlı tez çalışması 23/11/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Ferruh YILDIZ

.....

Danışman

Prof. Dr. Hakan KARABÖRK

.....

Üye

Prof. Dr. Hacı Murat YILMAZ

.....

Üye

Doç. Dr. Akif DURDU

.....

Üye

Doç. Dr. Murat UYSAL

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması ÖYP tarafından 2017-ÖYP-031 no’lu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Hasan Bilgehan MAKİNECİ

Tarih:

ÖZET

DOKTORA TEZİ

İNSANSIZ HAVA ARACI İLE FOTOGRAMETRİK TEMELLİ GÖRÜNTÜ ALIMI VE UÇUŞ OPTİMİZASYONU

Hasan Bilgehan MAKİNECİ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Harita Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Hakan KARABÖRK

2020, 87 Sayfa

Jüri

Prof. Dr. Hakan KARABÖRK

Prof. Dr. Ferruh YILDIZ

Doç. Dr. Akif DURDU

Prof. Dr. Hacı Murat YILMAZ

Doç. Dr. Murat UYSAL

İnsansız Hava Araçları (İHA) ve İnsansız Hava Araçları Sistemleri (İHAS) son yüzyılın en önemli araştırma konularından biridir. Sivil kullanımın yaygınlaşması ve araştırmacıların kolay erişebilmesi sayesinde, doğal yaşamda ve insan hayatında çok önemli kullanım alanlarında İHAS'lar tercih edilmektedir. Hızla gelişen İHAS teknolojisi yardımıyla, yeni konular ortaya çıkmakta ve herkese hitap eden araştırmalar yapılmaktadır. Son yıllarda haritacılık alanında İHA kullanımının artması beraberinde birtakım problemlerinde oluşmasına sebep olmuştur. Özellikle araştırmacıların üzerine çalışmalar yaptıkları konulardan biri de İHA uçuş optimizasyonudur. Günümüzde birçoğunun (güneş pili taşıyanlar hariç) yakıtı sonlu kaynaklar tarafından sağlanan İHA'lar için enerji çok önemlidir.

Gündelik hayatta insan beyninin kendiliğinden yaptığı optimizasyon işlemleri yakın zamanda, insan gibi düşünebilen Yapay Zeka (YZ) uygulamalarına konu olmaktadır. Bilgisayar öğrenmesi, derin öğrenme, Yapay Sinir Ağları (YSA) ve bunlara benzer birçok optimizasyon algoritması da YZ çalışmalarının ilerlemesine vesile olmaktadır. YZ algoritmalarının elektronik işlerdeki optimizasyon ihtiyacını gidererek gündelik hayata yönelik önemli avantajlar sağlayacağı aşikardır.

Bu çalışmada amaç, İHA'nın fotogrametrik kullanımında havada kalabileceği optimum koşulları belirlemek ve sonuçları analiz ederek uçuş optimizasyonunu gerçekleştirebilmektir. Bu amaca uygun olarak havada kalma süresine etki eden tüm parametreler çeşitlendirilerek, farklı deney sonuçları gözlemlenmiştir. Kırsal alan, kentsel alan gibi farklı tip alanlarda ve eğimli arazi, çok eğimli arazi gibi farklı eğim koşullarında yapılan arazi çalışmaları sonucunda elli üç adet deneme uçuşu gerçekleştirilmiş ve gözlemler kayıt edilmiştir. YSA kullanılarak yapılan optimizasyon çalışmasında, arazide gerçekleştirilen elli üç farklı İHA uçuşunda belirlenen girdi parametreleri (İHA Tipi, Yer

Örnekleme Aralığı, Bindirme Oranı ve Atmosferik Koşullar) kullanılarak eğitilmiş ağ ile çıktı parametreleri olarak belirlenen Batarya Durumu ve Uçuş Süresi test edilmiştir. Fotogrametrik ürünler üretilecek şekilde alınan görüntüler değerlendirilerek, uçuş planlaması parametrelerinin optimizasyonu hedeflenmiştir. Uçuş optimizasyonu bir bütün olarak ele alınarak girdi parametreleri çeşitlendirilip, çıktı parametrelerin regresyon değerleri irdelenmiştir. YSA çerçevesinde farklı eğitim algoritmalarının (Gradient Descent –GD- Algoritması ve Levenberg-Marquet - LM- Algoritması) optimizasyona etkileri araştırılmış, girdilerin normalizasyon öncesi ve sonrası durumları karşılaştırılmıştır. Sonuçların kullanıcıya ulaşması amacıyla bir grafik tabanlı arayüz hazırlanarak optimize edilmiş veriler grafik arayüze altlık olarak atanmıştır. Geliştirilen grafik ara yüzün haritacılıkta en sık kullanılan uçuş planlamalarına örnekler tanımlayarak, optimizasyon için fikir vermesi hedeflenmiştir. Sonuçlar tüm girdi parametrelerinin kullanıldığı optimizasyon modelinin en iyi sonuçlar için GD algoritmasında normalizasyon sonrası verilerle %82 doğrulukla tahmin yürüttüğünü ortaya koymuştur. Farklı parametrelerin optimizasyondan çıkarıldığı tahmin sonuçlarında da en iyi sonuçların normalizasyon öncesi verilerle GD algoritmasında %69 olduğu görülmüştür. Sonuç olarak fotogrametrik amaçlı İHA kullanımında uçuş optimizasyonunun YSA ile optimizasyonunun gerçekleştirildiği belirlenmiştir.

Anahtar Kelimeler: Gradient Descent Algoritması, İHA Fotogrametrisi, İHAS, Levenberg-Marquet Algoritması, Optimizasyon, Sayısal Görüntü Eşleme, Uçuş Planlaması, Yapay Zekâ, YSA

ABSTRACT

PhD THESIS

PHOTOGRAMMETRIC BASED IMAGE ACQUISITION AND FLIGHT OPTIMIZATION BY UNMANNED AERIAL VEHICLE

Hasan Bilgehan MAKİNECİ

**Konya Technical University
Institute of Graduate Studies
Department of Geomatics Engineering**

Advisor: Prof. Dr. Hakan KARABÖRK

2020, 87 Pages

Jury

Prof. Dr. Hakan KARABÖRK

Prof. Dr. Ferruh YILDIZ

Doç. Dr. Akif DURDU

Prof. Dr. Hacı Murat YILMAZ

Doç. Dr. Murat UYSAL

Unmanned Aerial Vehicles (UAV) and Unmanned Aerial Vehicles Systems (UAS) are one of the most important research topics of the last century. Due to the widespread use of civilians and easy access by researchers, UAS are preferred in critical areas of use in nature and human life. Due to the rapidly developing UAS technology, new issues arise, and researches that appeal to everyone are carried out. The increase in the use of UAVs in the field of geomatics engineering in recent years has led to some problems. One of the subjects that researchers especially work on is UAV flight optimization. Today, energy is vital for UAVs, most of which (except those carrying solar cells) are fueled by finite sources.

In daily life, the spontaneous optimization processes of the human brain have recently been the subject of Artificial Intelligence (AI) applications that can think like a human. Computer learning, deep learning, Artificial Neural Networks (ANN) and many similar optimization algorithms are also effective in the improvement of AI subjects. It is obvious that AI algorithms will provide important advantages for daily life by solving the need for optimization problems in electronic industry.

The purpose of this research is to determine the optimum conditions underneath that the UAV will keep within the air and perform flight optimisation by analyzing the leads to photogrammetric use. Following this purpose, all parameters regarding the flight time were diversified, and different check results were observed. As a result of the field studies performed in different types of areas such as rural areas, urban areas and different slope conditions such as sloping area and multi-slope area, fifty-three trial flights were managed, and observations were recorded. The Battery Status and Flight Time determined as output parameters were tested with the trained network using input parameters (UAV Type, Ground Sampling Range, Overlap Rate and Atmospheric

Conditions) determined in fifty-three different UAV flights performed at the field in the optimization study using ANN. The optimization of flight planning parameters was aimed by evaluating the images taken to produce photogrammetric products. Flight optimization is taken into account as a whole, the input parameters are varied, and therefore the regression results of the output parameters are examined. Within the framework of ANN, the effects of different training algorithms (Gradient Descent -GD- Algorithm and Levenberg-Marquet-LM-Algorithm) on optimization were investigated, and the states of inputs before and after normalization were compared. A graphical interface (GUI) was prepared, and optimized knowledge was connected to the GUI as a centre for the users to achieve the results. it's aimed to provide a concept for optimisation by process samples of flight designing that are most often employed in geomatics engineering. The results disclosed that the optimization model, within which all input parameters were used, calculable with 82% accuracies with post-normalization data within the GD algorithmic rule for the most effective results. within the estimation results wherever completely different parameters were excluded from the optimization, it absolutely was seen that the best results were 69% in the GD algorithm with pre-normalization data. As a result, it absolutely was determined that the optimisation of the flight with ANN within the use of photogrammetric UAVs.

Keywords: ANN, Artificial Intelligence, Gradient Descent Algorithm, Flight Planning, Levenberg-Marquet Algorithm, Optimization, UAS, UAV Photogrammetry

ÖNSÖZ

Bu tez çalışmasında İnsansız Hava Aracı Sistemlerinin fotogrametrik temele dayalı kullanımlarda havada kalma sürelerinin optimize edilmesi, farklı test alanlarından elde edilen uçuş planlamalarını kullanarak incelenmiştir. Optimizasyon için yapay zekâ uygulaması olarak Yapay Sinir Ağları kullanılarak sonuçların analiz edilmesi hedeflenmiştir.

Tez çalışmamda konu seçiminde, uygulamalarda ve tüm işlemlerde her türlü desteğini çekinmeden bana sunan değerli danışmanım Prof. Dr. Hakan KARABÖRK hocam başta olmak üzere, laboratuvar donanımlarını sınırsız kullanımımıza sunan Prof. Dr. Ferruh YILDIZ hocama ve tecrübesinden, bilgisinden her zaman destek aldığım Doç. Dr. Akif DURDU hocama ve adını burada yazamadığım tüm hocalarıma, arkadaşlarıma teşekkürü bir borç bilirim.

Bugünlere gelmemde maddi ve manevi en büyük pay sahibi olan ve beni her konuda cesaretlendiren, sonsuz desteklerini esirgemeyen değerli ailemin tüm fertlerine gönülden teşekkür ederim.

Hasan Bilgehan MAKİNECİ
KONYA-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER.....	ix
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	5
3. MATERYAL VE YÖNTEM.....	14
3.1. Kullanılan İHA'lar.....	14
3.1.1. Sabit kanatlı İHA	14
3.1.2. Döner kanatlı İHA'lar	16
3.2. Çalışma Bölgeleri	17
3.3. Hava Fotogrametrisi İş Akışı.....	22
3.3.1. Hava fotogrametrisi uçuş planlaması.....	25
3.3.2. Fotogrametrik İHA kullanımı için temel görüntü alımı.....	27
3.3.2.1. İHA fotogrametrisi iş akışı	28
3.3.2.2. Uçuş yüksekliğinin (Yer Örneklem Aralığı) ve ileri/yan bindirme oranlarının hesaplanması	29
3.3.2.3. Fotogrametrik amaçlı İHA kullanımında sonuç kontrolleri	33
3.3.2.4. Koordinat dönüşümleri ile alakalı yapılan çalışmalar	37
3.4. Optimizasyon	38
3.4.1. Yapay sinir ağları.....	39
3.4.2. Yapay sinir ağları ile optimizasyon ve algoritma yapıları	40
3.4.3. YSA eğitim algoritmaları.....	43
3.4.4. Normalizasyon işlemi	45
3.5. Grafik tabanlı arayüz	45
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	48
4.1. Arazi Çalışmaları Bulguları	48
4.2. İHA Uçuşlarından Üretilen Sonuç Ürünler	56
4.2.1. İHA görüntülerinin fotogrametrik olarak kullanılabilirliği ve dengeleme sonuçları.....	59
4.3. Optimizasyon problemi ve İHA için uçuş parametreleri optimizasyonu	64
4.3.1. Optimizasyon için YSA algoritmasının kullanımı.....	65
4.4. Optimizasyon ve Bulguları	66
4.5. Optimizasyon Sonrası Geliştirilen GUI.....	81

5. SONUÇLAR VE ÖNERİLER	85
5.1 Sonuçlar	85
5.2 Öneriler	87
KAYNAKLAR	88
EKLER	95
ÖZGEÇMİŞ	115



SİMGELER VE KISALTMALAR

Simgeler

W_{θ} :	Girdi parametrelerin her birinin ağırlıklarını ifade eden fonksiyon
Θ :	Girdi parametrelerin her birini ifade eden fonksiyon
$\eta\omega$:	Ağ ağırlıklarını tespit eden fonksiyon
J_i :	Jacobian matrisi
I :	Birim matris
Λ :	Marquard parametresi
α :	Öğrenme oranı
θ :	Maliyet fonksiyonu
$^{\circ}$:	Derece
μ :	Performans fonksiyonu
$X_{\min}$:	Girdi kümesindeki en küçük sayı
$X_{\max}$:	Girdi kümesindeki en büyük sayı
X_n :	Girdi değerlerin her biri

Kısaltmalar

CORS:	(Continously Operating Reference Stations) Gerçek Zamanlı Ulusal Sabit İstasyonları
ED50:	Avrupa Datumu-1950 (Hayford elipsoidine dayalı datum)
FOS:	Fiber Optik Sensör
GZK:	Gerçek Zamanlı Kinematik
GNSS:	(Global Navigation Satellite Systems) Küresel Navigasyon Uyduları Sistemi
GUI:	Graphical User Interface), Grafiksel Kullanıcı Arayüzü
IMU:	(Inertial Measurement Unit) Ataletsel Ölçü Birimi
INS:	(Inertial Navigation Systems) Ataletsel Konumlama Sistemi
ITRF:	(International Terrestrial Reference Frame) Uluslararası Yersel Referans Çerçevesi
ITRF96:	1996 yılında güncellenmiş ITRF
İHA:	İnsansız Hava Aracı
İHAS:	İnsansız Hava Aracı Sistemleri
KOH:	Test edilecek veri kümesi değerleri ile aynı veri kümesinin daha yüksek doğrulukta bağımsız bir kaynaktan elde edilen değerleri arasındaki farkların karelerinin ortalamasının karekökü
LIDAR:	(Light Detection and Ranging) Lazer (Işık) ile Yüzey Uzaklıklarının Belirlenmesi ve ölçümü
PZT:	Piezoelektrik Sensör
RTK:	Real Time Kinematik (GZK)
SAR:	Sentetik Açıklıklı Radar
SAM:	Sayısal Arazi Modeli
SYM:	Sayısal Yükseklik Modeli
TGyy:	TUDKA99 ile ilişkilendirilmiş, yayımlandığı yılın son iki rakamı ile adlandırılan ve Harita Genel Müdürlüğü tarafından güncellenen Türkiye Jeoit Modeli
TUREF:	Türkiye Ulusal Referans Çerçevesi [Koordinatları ITRF96 ile 2005,0 referans epogunda çakışık ve koordinatlarının zamana göre

	doğrusal değişimi (hızları) ITRF96'nın Sıfır Net-Dönüklüğüne göre tanımlı dört boyutlu ulusal datum]
TUSAGA:	Türkiye Ulusal Sabit GNSS Ağı-Aktif (GZK hizmeti veren GNSS Ağı)
TUTGA:	Türkiye Ulusal Temel GNSS Ağı
YSA:	Yapay Sinir Ağları
YÖA:	Yer Örneklem Aralığına



1. GİRİŞ

Son yüzyıl boyunca gelişen fotogrametrik yöntemlerin sunduğu avantajlar sayesinde haritacılıktan inşaat, madencilikten ziraate, arazi değişikliklerinden doğal felaketlerin belirlenmesine/izlenmesine hemen her alanda ivmelenme yaşanmaktadır (Samad ve ark 2013, Uysal ve ark 2015, Makineci 2016, Xiang ve ark 2018, Yılmaz ve ark 2018, Nex ve ark 2019, Rizo-Maestre ve ark 2020). Özellikle hava fotogrametrisinde ve dijital kamera teknolojisinde yaşanan ilerlemeler ile çok bantlı metrik kameraların sunduğu yüksek çözünürlük, fotogrametri biliminin baş döndürücü ilerlemesine öncülük etmektedir (Kolláth ve ark 2020). Özellikle kameraların laboratuvar ortamlarında yüksek doğrulukta belirlenen iç yönelme parametrelerinin, bu parametrelerin matematik modelde kullanılması sonucunda ölçme ve değerlendirme doğruluğunu artırmaktadır (Chen ve Pan 2020). Bu sayede günümüzde dijital kameraların kullanımı artarak ve sağladığı avantajlar nedeniyle uygulamaların vazgeçilmez donanımı olmuşlardır. Hava fotogrametrisine benzer olarak İnsansız Hava Aracı (İHA) fotogrametrisi ise metrik olmayan düşük bütçeli dijital kameraların tercih edildiği bir yöntem olarak kullanıcılara yenilikler sunmaktadır (Lichti ve ark 2019, Tjahjadi ve ark 2019). İHA'lar mevsimsel olarak geniş bir dönemde kullanılabilir olması (Rosnell ve ark 2011), yasal mevzuatının daha az zorlayıcı olması (Kahveci ve Can 2017, Çoban ve Oktay 2018), maddi gereksinimlerin daha uygun olması ve uçuş planlamasında daha geniş alternatifler sunması dolayısıyla günümüzde popüler bir araştırma konusu olarak görülmektedir.

İnsansız Hava Aracı (İHA) ve İnsansız Hava Aracı Sistemleri (İHAS) genel olarak birbirinin neredeyse aynısı kavramlardır. Literatürde genel olarak bu iki kavram kullanılmaktadır (Fahlstrom ve Gleason 2012). Özellikle yabancı dil kökenli bir kavram olduğu için dron (drone) ile iç içe girmektedir. Dron ülkemizde akademik olmayan çalışmalarda döner kanatlı İHA için kullanılmaktadır. Sabit kanatlı İHA ise, kullanıcılar tarafından İHA olarak tanımlanır. Fakat sabit kanatlı, döner kanatlı veya hibrid tüm sistemlerin genel adı İHA'dır. Teknik anlatım olarak; içinde ve üzerinde herhangi bir yolcusu ve pilotu olmayan yer yüzeyinden yüksek irtifada seyredebilen ve uzaktan kumanda edilebilen hava araçlarına İHA denilmektedir. Genel itibarıyla dünyada İHA konusu robotik çalışmalar başlığı altında araştırılmaktadır (Maxim ve ark 2017, Cho ve ark 2018, Macharet ve Campos 2018, Polat ve Uysal 2020). Robotik çalışmalar son zamanlarda dünyanın en önemli araştırma konularının başında gelmektedir. Bu alanda çığır açıcı gelişmeler günden güne olmaktadır. İHAS kullanıcı (pilot) tarafından yönlendirilen ve ortam koşullarının, yasal sorumlulukların ve güvenli uçuş yapabilmenin İHAS'ın pilotunun sorumluluğunda olduğu bir çeşit makinedir. Yönlendiren

kişinin İHAS özelliklerine hâkim olması, ortam koşullarını iyi analiz edebilmesi ve tüm sorumluluklarına uygun etik değerler ile uçuş yapması çok önemlidir (Kahveci ve Can 2017, Çoban ve Oktay 2018). Bir bu kadar daha önemli olan konu ise yapacağı uçuşun optimizasyonunu sağlamasıdır (Zhang ve ark 2010, Arantes ve ark 2016, Zhang ve ark 2016, Radmanesh ve ark 2018, Dewangan ve ark 2019). İHA'lar genellikle verilen görevleri yerine getirerek hedef sonuç ilişkisini olumlu tamamlamaktadırlar. Fotogrametrik olarak sonuçların yeterli olması, İHA bataryalarının ve uçuş sürelerinin negatif yanlarına çare olamamaktadır (Haala ve ark 2011, Cryderman ve ark 2014). Kısa süreli uçuş yapılmasına imkan veren bataryalarından dolayı uçuş sürelerini optimum düzeyde kullanmak için fotogrametrik temel parametrelerin uçuş süresine ve batarya durumuna olan etkilerinin bilinmesi gereklidir (Remondino ve ark 2011).

Bu çalışmanın önemi daha önce tüm fotogrametrik parametrelerin birlikte değerlendirildiği ve uçuş süresi ile batarya durumuna nasıl etki ettiğini belirleyen ve bunların optimizasyonu üzerine araştırma yapan bir çalışmanın olmamasıdır. Yüksekliğin, bindirme oranlarının, İHA tipinin ve atmosferik koşulların, uçuş süresine ve batarya durumuna ayrı ayrı yaptıkları etkileri araştıran çalışmalar olmakla birlikte (Hernandez-Lopez ve ark 2013) bu çalışmalar bazen tamamen simülasyona dayalı (Behnck ve ark 2015, Martin ve ark 2016, Dewangan ve ark 2019, Tan ve ark 2019), bazen daha az veri ile yapılmış (Krause ve ark 2016) veya bazen de sonuçların optimizasyonu araştırılmamış olarak vardır (Prasetia ve ark 2019). Bu çalışma gerçek arazi koşullarında yapılmış, çok veriden faydalanılmış, fotogrametrik amaçlı planlanmış ve yapay zekâ uygulamalarıyla değerlendirilmiş ilk çalışma olarak görülmektedir.

Çalışma öncesi yapılan araştırmalarda ortaya çıkarılan problem, fotogrametrik amaçlı İHA kullanımında bir optimizasyon standartı bulunmamasıdır. Fotogrametrik planlama, çalışma yapılacak belirli bir hat üzerinden, veri toplama işinin kısıtlı bir sürede gerçekleştirilmesine dayanmaktadır (Gandor ve ark 2015, Gómez-López ve ark 2020). Literatürde, İHA uçuş planlamasıyla alakalı yapılan çalışmaların arazi verisinin optimizasyonuna (eğitim ve test verisi ilişkisine) dayalı olmadığı görülmektedir (Rojas 2014, Chiabrando ve ark 2017, Pepe ve ark 2018, Roth ve ark 2018). Araştırmalar İHA'ların günümüzde fotogrametride çok sık kullanılan fakat net bir optimizasyon standardı bulunmayan teknik ekipmanlar olduğunu göstermektedir. Fotogrametrik amaçlı İHA kullanımında bulunan optimizasyon çalışmaları ya İHA'nın havada kalma süresini tamamen etkileyen tüm parametreleri barındırmamaktadır ya da simülasyonda üretilen verilere dayalı olarak eğitim ve test aşamalarında geçmekte ve çok güvenilir bir optimizasyon oluşturmamaktadır. Bu çalışmada tespit edilen bu eksikliğin giderilmesi ile:

- İHA sistemlerinin havada kalma süreleri kısıtlı olması,
- Uçuş sürelerinin kullanıcılar tarafından doğru tahmin edilememesi,
- Fotogrametrik iş akışı çerçevesinde uygun planlamanın seçilememesi sebeplerine uygun bir çözüm bulunmasının gerçekleşmesi istenmektedir.

Belirlenen problemin çözümü için yapılan çalışmalarda amaç gerçek arazi koşullarında İHA ile yapılacak fotogrametrik temelli uçuşların planlamasında, gerçekleştirilmesinde ve sonuçlandırılmasında kullanılacak bir optimizasyon modeli kurmaktır. Optimizasyon modelinin geçerli ve makul sayılabilmesi için yapay zeka algoritmalarından konuya en uygun ve en yüksek doğrulukta tahminler üretebilecek algoritmayı belirlemektir.

Çalışmanın amacını gerçekleştirmek için belirlenen hedeflerden birincisi, yersel ölçümlerle desteklenmiş İHA uçuşları gerçekleştirmektir. Ek olarak, yapılan İHA uçuşlarında farklı sonuçlar ortaya çıkarması mümkün koşulların (uçuş yüksekliği, bindirme oranları, arazi tipi, arazi eğimi, İHA tipi ve atmosferik koşullar) değiştirilmesini sağlayarak, optimizasyon modeli oluşturabilmek için deneylerin kaydedilmesidir (Özemir ve Uzar 2016, Öztürk ve ark 2017, Cho ve ark 2018, Barba ve ark 2019, Manconi ve ark 2019). İkinci hedef olarak, optimizasyon için belirlenen girdi parametreleriyle çıktı parametrelerinin uyumlu olup olmadığının belirlenmesi ve optimizasyon modeli oluşturabilmek için uygun bir algoritma seçimi yapılmasıdır. Ardından seçilen algoritmanın vermiş olduğu sonuçların analiz edilmesidir. Belirlenecek algoritmanın hedefe uygun olması için; iyi bir öğrenme yeteneğinin olması, doğrusal olmayan problemleri çözebilir olması, sağlam (robust) olması ve hata toleransının yüksek olması gerekmektedir. Seçilen hedefler için ilk performans göstergesi olarak, Yer Kontrol Noktalarının (YKN) yersel ölçmelerin mümkün olduğunca yüksek doğrulukta ve tutarlılıkta yapılması ayrıca arazide homojen dağılmasının sağlanmasıdır. Bu çalışmada 53 farklı uçuş için 300'den fazla Yer Kontrol Noktası (YKN) arazide kireç, boya gibi araziye kontrast olacak şekilde işaretlenmiştir (Fidanci ve Karabörk 2019). YKN'ler, koordinat ölçüm doğruluğunun uygun olduğu literatürde belirlenmiş olan Sürekli Gözlem Yapan Referans İstasyonları TUSAGA-Aktif -İngilizce kısaltması olan CORS (Continuously Operating Reference Stations)- yöntemiyle ölçülmüştür (Inal ve ark 2018). İkinci performans göstergesi ise uçuş planlamalarında mantıklı ve kabul edilebilir farklılıklar yaratarak literatürden tespit edilen ve optimizasyona uygun olacağı düşünülen tüm parametrelerin araştırılmasıdır. Yapılan uçuşlarda arazi tipi, arazi eğimi, uçuş yüksekliği (Yer Örnekleme Aralığı – YÖA), bindirme oranı (BO), İHA tipi ve atmosferik koşullar (AK) gibi farklı parametreler (Hernandez-Lopez ve ark 2013, Manconi ve ark 2019) 53 uçuş için tek tek değiştirilerek batarya durumu (BD) ve uçuş süresi (US) kayıt altına alınmıştır. Çalışmalarımızda yapılan toplam deney sayısını en iyi

temsil edebilecek ve literatürde alternatifleri içinde bu araştırmaya en yatkın olarak görülen bir yapay zeka algoritması araştırılmıştır (Zhang ve ark 2010, Arantes ve ark 2016, Zhang ve ark 2016, Radmanesh ve ark 2018, Herrero-Huerta ve ark 2020). Bu araştırma sonucunda Yapay Sinir Ağları (YSA) uygun görülmüş ve optimizasyonda kullanılmıştır. Son performans göstergesi ise girdi olarak benimsenen tüm parametrelere ilişkin arazide yapılan çalışmalar öncülüğünde optimizasyona uygun olan ve olmayan parametrelerin sınıflandırılmasıdır. Bir kısmı girdi olması planlanan parametrelerin matematik modele olumlu veya olumsuz etkileri araştırılarak optimizasyonda kullanılabilir olduğunun belirlenmesidir.

Bu çalışmada yapılan literatür araştırması, İHA kullanım alanlarının, optimizasyon konusunun ve bu çalışmada belirtilen yapay zeka konularının özetlendiği ve ilişkilendirildiği bir bölümdür. Ardından gelen materyal ve yöntem bölümünde de kullanılan İHA'lar, fotogrametrik standartlar, çalışma bölgeleri ve YSA, normalizasyon, grafik ara yüz konularından bahsedilmiştir. Materyal ve yöntem bölümden sonra araştırma bulgularının ve tartışmaların yapıldığı bölüm ve en son olarak sonuçların ve önerilerin anlatıldığı bölümler ile çalışma tamamlanmıştır.

2. KAYNAK ARAŞTIRMASI

İHA'ların kullanım alanları hemen hemen tüm bilim dallarına yayılmaktadır. Özellikle deformasyon tespiti, afet takibi amaçlı izleme gibi çalışmalarda önemli bir araç olarak kullanılmaktadır. Bu bağlamda; köprülerin eskimesi ve yapısal performansının bozulması durumunda köprüler için tasarlanan tasarım ömrünün ötesinde devamını sağlaması için düzenli bir yapısal değerlendirme ve müdahale için İHA kullanılabilir. Son yıllarda yapısal durum değerlendirmesinde temassız köprü izleme yöntemleri konusunda çok sayıda araştırma yapılmıştır. Yersel Lazer Tarama (YLT) güçlü bir alternatif olmaya devam etse de İHA tabanlı fotogrametriye ilgi artmaktadır. Görüntü tabanlı alt yapı değerlendirmesi için İHA kullanımı, veri üretimi ve işleme için bir çerçeve oluşturulan bir çalışmada İHA'ların uygun görüntü elde edebilmeleri için iyi bir uçuş planlanması gerekli olduğu belirtilmiştir (Barba ve ark 2019). Köprü gibi büyük yapılardan veri toplanması ve verinin yorumlanması, yönetilmesi ve saklanması için büyük miktarda gayret gerektirir. 3B modellerin kalitesi büyük ölçüde elde edilen görüntülerle yapının biçimine bağlıdır. Çalışmalarda sunulan çerçeve, bu tür iş akışlarında yer alan tüm algoritmaların otomatikleştirilmesi yönünde önemli bir adımı işaret etmektedir (Morgenthal ve ark 2019). Yapılan çalışmalarda, veri toplama uygulamalarında sıklıkla kullanılan İHA'ların arkeolojik kazı alanlarında arazi tipinin belirlenmesi, Sayısal Arazi Modeli (SAM) elde edilmesi, arazinin topoğrafik yapısının saptanması işlemlerinde de kullanılabilirliği araştırılmıştır (Remondino ve ark 2011). Bu amaçla, kazı alanına girmeden, önceden planlanan rotaya göre arkeolojik çalışma alanının görüntüleri İHA'nın alt kısmına yerleştirilmiş kompakt kamera kullanılarak uçuş gerçekleştirilen bir İHA ile nokta verisi, alanın ortofoto haritası ve SAM üretilmiştir (Linder 2009, Kolláth ve ark 2020, Sanz-Ablanedo ve ark 2020, Ulukavak ve ark 2020). Bu tarz insanlık tarihi açısından önemli işlerde İHA kullanımının gerekliliği ve bilgili, tecrübeli kişilerce İHA uçuşlarının yapılması gerekliliği vurgulanmıştır.

İHA'ların zamansal, ekonomik ve boyutsal olarak klasik ölçümlere göre ilerde olması birçok alanda İHA tercih edilmesinin ana nedenlerinden biridir (Fahlstrom ve Gleason 2012, Hernandez-Lopez ve ark 2013). Yapılan bir çalışmada test alanı olarak seçilen bir meradaki söğütlerden beslenen çiftlik hayvanlarının, söğütler üzerindeki etkisini ve meraların hayvancılık açısından kullanımını incelemek için İHA'lar ve yersel teknikler ile ölçümler yapılmış ve bu iki veri karşılaştırılmıştır. Sonuçlar yüksek uyumlu çıktığından dolayı İHA'ların bu gibi alanlarda gözlemler ve denetlemeler için kullanılmasının hem ekonomik hem de kolay bir yöntem olduğunu göstermiştir (Karl ve ark 2020). Buna benzer bir çalışmada da İHA'lar ile tarımda bitkilerin mahsul üretimi arttırmak için bitki fenotolojisinin kolay ve

otomatik bir şekilde yapılmasını sağlamak mümkün müdür diye araştırılmıştır. Bunun sonucunda çiftçiler ekonomik ve pratik bir şekilde bitkilerin büyüme durumu, hastalık tespiti, yaşlılık oranı, su ihtiyacı gibi bulgulara ulaşılmıştır (Herrero-Huerta ve ark 2020). Farklı sensörlerle de İHA biokütle hesapları sıkça yapılmaktadır. İHA'ya entegre edilen multispektral sensörler vasıtasıyla alan taranmış ve bölge biokütlesi tespit edilirken buna etki eden faktörler bulunmaya çalışılmıştır. Buna göre yerüstü biokütlesinin tespit önemi de anlatılmaya çalışılmıştır. Tarım arazilerindeki bitkilerin izlenerek verim artışını desteklemeye, tarım dışı alandaki bitkilerin de özelliklerinin tespit edilerek veri tabanı oluşturmaya yardımcı olan uzaktan algılama sisteminin önemi görülmüştür. Entegre edilen sensörün RGB özelliği sayesinde, RGB ve AGB karşılaştırması mümkün kılınmıştır. RGB'nin spektral aralığı sebebiyle AGB'ye göre daha avantajlı olduğu saptanmıştır. Uzaktan algılamada uydu görüntüleri yerine İHA'ların kullanılmaya başlanması özellikle mekânsal çözünürlük bakımından önemli hale gelmiştir (Poley ve McDermid 2020).

Yapılan bir makalede ise, Fırat Üniversitesi kampüsünde 3 farklı test alanı seçilmiştir. Test alanlarında ortalama yükseklikleri 13m olan sırasıyla 46, 144, 133 adet ağaç bulunmaktadır. Uçuş bölgesinde eşit olmak suretiyle 7 tane yer kontrol noktası kurulmuş ve bunlar RTK-GPS ile ölçülmüştür. Kampüste uçurulan İHA DJI Phantom 3 ve sahip olduğu kamera FC300X dijital kameradır. 141 m yükseklikten 321 görüntü alımı yapılmıştır. 25 dk boyunca süren uçuşta, görüntü boyutu 4000x3000 piksel olan ve daha iyi SAM üretmek için %80 yan ve ileri bindirme sahip olan görüntüler alınmış olup işlenmesi için Agisoft Photoscan Professional (APP) yazılımı kullanılmıştır. Çalışmanın amacı doğrultusunda m² başına 144.6 nokta yoğunluğuna sahip nokta verisi oluşturulmuş ve sonrasında 15 cm'lik SAM ve ortofoto elde edilmiştir. Bu da bilineer enterpolayson algoritmasıyla enterpole edilmiştir. Çalışmada kullanılacak PFB (polinomal bağlantı esaslı) yöntemi için SAM, rastgele üçgenler ağı algoritması ile filtrelenmiştir. Ağaç taç çaplarını tanımlamak için segmentasyon işlemi gerçekleştirilmiştir. Bu bağlamda MSS, MPBS, MRS, SRGS VE WS sınıflandırma teknikleri kullanılmıştır. Taç çapının belirlenmesi daha önceleri Lidar ile belirlenirken bu çalışma İHA ile gerçekleştirilmiş ve doğal olarak daha uygun maliyetle tamamlanmıştır. Literatürde benzer örnekleri bulunan bu çalışma da fotogrametrik değerlendirme alanında çalışacak uygulayıcılara fayda sağlayabileceği belirlenmiştir (Yılmaz ve Güngör 2019).

Yapılan araştırmalarda, insanlı ve/veya insansız bir helikopterin tasarım parametrelerinin çevresel koşullara bağlı olarak dikkate alınması gerektiğine dair kanıtlar sunulmaktadır. Ortam sıcaklığının ve basıncın rakımla değişen motorun tüm bileşenleri üzerindeki etkisi, ekserji tahribatı oranı olarak görünür. Bu nedenle, gerekli tasarım

parametrelerini belirlemede ortam sıcaklığını ve basıncını analiz etmek gerektiğine vurgu yapmaktadır. İHA, kalkış aşamasında maksimum güç gereksinimlerine ihtiyaç duyduğundan ve gücü sıcaklık, basınç ve diğer birçok parametreyle ilişkili olduğundan, kalkış aşaması tüm uçuş aşamalarında önemli bir süreçtir (Ekici 2020). Genel anlamda İHA'lar ile klasik insan taşıyan uçakların benzer motor tiplerine sahip olduğu bilinmektedir. Ancak İHA motorlarının birbirlerine karşı olan avantaj ve dezavantajları söz konusudur. Bu amaçla araştırmalar yapılırken İHA'ların uçuş yüksekliği, havada kalış süresi, iniş ve kalkış ağırlığı gibi performans özellikleri göz önünde bulundurulmaktadır. İHAS kullanılan farklı güç kaynaklarına sahip çeşitli sürücü sistemleri bulunduğunu göstermektedir. Pistonlu motorlar ve elektrikli motorlar en yaygın kullanılan motor tipleridir. İHA'lar insanlı hava araçlarında olduğu gibi motor boyutları ve tipinin yanı sıra uçak boyutları ve ağırlıkları açısından da farklılık gösterir. Elektrikli motorlar genelde hafif ve küçük modellerde kullanılırken, pistonlu motorlar ağır ve büyük modellerde kullanılır (Çoban ve Oktay 2018).

Günümüzün gelişen teknolojisinde hareketli, yoğun ve karmaşık ortamlarda hareketli nesnelerin tanımlanması ve takip edilmesi konuları hala zorluklar bulunmaktadır. Fakat son zamanlarda İHA'lara ve donanım teknolojilerine artan ilgi sebebiyle hareketli nesnelerin takibi konusunda yapılan çalışmalar hareketli nesnelerin takibini kolaylaştırmayı başarmıştır. Bu amaçla yapılan araştırmada; İHA ile çekilen görüntüleri kullanılarak transfer öğrenme yöntemi yardımıyla, yaya tespitine yönelik bir uygulama gerçekleştirilmiş ve kullanılan ESA (Evrişimsel Sinir Ağları) modellerinin performanslarını karşılaştırılmıştır. Transfer öğrenme yöntemi en basit tanımıyla daha önceden eğitilmiş bir modelin kullanılmasıdır. Bu çalışmanın başka bir amacı da transfer öğrenme yöntemi ve görüntü çoğaltma işleminin hareketli nesne tespitindeki doğruluklarının incelenmesidir. Sonuçta, farklı algoritmalar arasında oluşan ufak farklılıkların sebebinin, eğitim süreçleriyle ilgili olduğu belirlenmiştir. Çalışmada kullanılan farklı ESA modellerinin performansları karşılaştırıldığında transfer öğrenme yönteminin verileri ayırt edebilmede ki yeteneği ortaya koyulmuştur. Kullanılan bir başka yöntem olan görüntü çoğaltma işleminin ise yeterli veri çokluğunun sağlanamadığı durumlarda da kullanılabilecek nitelikte olduğu görülmüştür (Toraman 2018). Yapılan başka bir çalışmada, İHA'lar yardımıyla çekilen görüntülerin işlenmesiyle elde edilen sonuç ürünlerdeki nesne boyutunun uçuş yüksekliğine bağlı olup olmadığı araştırılmıştır. Bu amaçla, farklı uçuş yüksekliklerinden aynı dijital hava kamerası kullanılarak ve aynı uçuş planı gerçekleştirilerek, dünya yüzeyinde sabit küçük bir nesnenin uzunluk, alan ve hacimsel farklılıklarının karşılaştırılması yapılmıştır. Sonuç olarak İHA'nın uçuş yüksekliği arttıkça, nesnenin boyutunun dikdörtgen şeklini koruyamadığı görülmüştür. Bu nedenle, her ölçümde farklılıklar

olduğu saptanmıştır. Nesnenin gerçek genişliği ve uzunluğu, ortomozaik ve nokta bulutu verileri ile karşılaştırıldığında, hata değerinin uçuş yüksekliği ile birlikte arttığı gözlemlenmiştir. Ayrıca, ardışık irtifadaki verilerin daha yakın ölçümlere sahip olduğu gözlenmiştir. Nesnenin alan ölçümleri karşılaştırıldığında, 10 m yüksekliğinde gerçekleştirilen uçuş verilerinin gerçek boyuta daha yakın olduğu görülmüştür. Farklı yüksekliklerden üretilen verilerin alansal değerleri karşılaştırıldığında, gerçek boyutla orantılı olarak %0,34 ile %3,7 arasında farklılıklara sahip oldukları görülmüştür. Aynı zamanda alan ölçümlerinde nokta bulutu verilerinin gerçek ölçümlere ortomozaik verilerden daha fazla yaklaştığı tespit edilmiştir. Hacim değerleri incelendiğinde, uçuş yüksekliği arttıkça hata değerinin de arttığı görülmüştür. Gerçek hacim değerine en yakın değer, 10 m yükseklikte gerçekleştirilen uçuştan elde edilen nokta verisi ve SAM verisinde bulunmuştur. Hacim değerleri karşılaştırıldığında, nokta bulutu verilerinin SAM verilerinden daha doğru değerler verdiği görülmüştür. İHA ile oluşturulan verilerden elde edilen boyutların gerçek değerlerle karşılaştırılmasında tüm uçuş yüksekliklerinin benzer olduğu görülmüştür. Ancak, en iyi hacimsel benzerlik sadece en düşük uçuş yüksekliğinde elde edilmiştir. Ayrıca, uçuş yüksekliği arttıkça küçük nesnelerin şeklini koruyamadıkları bulunmuştur. Nokta bulutu verilerinin nesne şeklini SAM'den daha iyi koruduğu da anlaşılmıştır. Yani, İHA'lar küçük nesnelerin genişlik, uzunluk ve alan hesaplamalarında kullanılabilir hata sınırları içerisinde veri üretebilmektedirler denilebilir (Akay ve ark 2020).

İHA'lar kullanılarak ortorektifiye edilmiş hava görüntüleri birkaç saat için de elde edilebilmektedir (Haala ve ark 2011, Forlani ve ark 2018, Inal ve ark 2018). Bir projede ABD/Texas eyaletine bağlı Nacogdoches bölgesinde yedi ay boyunca ayda bir kez olmak üzere “Oak Grove” mezarlığı üzerin de DJI Phantom İHA uçurulmuş ve yedi ayrı ortomozaik görüntü elde edilmiştir. Mezarlıkta kalıcı olacak otuz YKN tesis edilmiş ve oluşan yedi ortomozaik görüntüden de bu otuz YKN coğrafi koordinatları okunarak kaydedilmiştir. Okunan bu noktalar üzerinde yapılacak analizlerin elde edilecek ortomozaiklerin konumsal hassasiyeti hakkın da fikir vereceği düşünülmüştür. Analiz “Belirli bir zaman aralığında, İHA tarafından kaydedilen hava görüntüsünden türetilen ortomozaik üzerinden okunan aynı nokta için sürekli aynı coğrafi koordinatlar elde ediliyor mu?” sorusuna cevap aramaktadır. Ayrıca konum hassasiyeti İHA uçuşunun yönüne paralel olarak daha düşük olup olmayacağı da araştırılmıştır. Pix4DCapture yazılımı ile programlanan yedi uçuşun her biri Drone2Map yazılımı ile işlenerek ortomozaik görüntüler elde edilmiştir. Belirlenen YKN'lere göre aydan aya karşılaştırılabilecek rektifiye edilmiş görüntüler elde edilmiştir. Ortaya çıkan görüntüler; zaman için de veriler de kuzeydoğu yönünde bir konumsal hassasiyet seyretilmesi (Duyarlılık Kaybı) olduğunu

göstermiştir. Çalışmadaki bir şekle bakıldığında orta kısımlardaki YKN'lerin konumsal hassasiyetinin daha yüksek olduğu görülmüştür. Karşılaştırma için mezarlık sınırı boyunca daha az örtülü alanlara kıyasla daha fazla örtülü alanlardaki YKN'lerin değerlendirilmesi daha doğru olduğu kanısına varılmıştır. Çünkü kenar bölgelerde konumsal hassasiyet düşük olarak gözlemlenmiştir. Bu yaygın olarak kenar efekti olarak bilinen bir sorun olduğu açıklanmıştır. Bu nedenle çoğu İHA uçuşlarında bu sorunu ortadan kaldırmak için uçuşlar proje alanının biraz daha dışına çıkacak şekil de planlanmalıdır denilmiştir. Bu sorun Pix4DCapture ile ayarlanan görüntü dizisi ile de ilgili olabilir. Görüntüler gridin kuzeydoğu köşesinde çekilmeye başlamış daha sonra güneye en son da güneybatı köşesinin görüntüleri çekilmiştir. Bu kuzeydoğudan güneybatıya olan geçiş, konumsal hassasiyetin uçuş yönü boyunca daha düşük olmasına sebep olacaktır. İHA'lardan elde edilen hava görüntülerinden türetilen ortomozaiklerde; ortomozaik merkezi, kenarlardaki alanlardan daha yüksek konumsal hassasiyete sahip olacaktır. Daha yüksek hassasiyet daha doğru konum bilgisi olarak bize dönecektir. Ortomozaik üretilirken yalnızca ortomozağin en doğru nerede oluşacağına değil uçuş yönüne de dikkat edilmelidir. Diğer faktörler arasında; kullanılan GPS alıcısı doğruluğu, kamera çözünürlüğü, kullanılan görüntü işleme uygulaması ve İHA uçuşu sırasındaki rüzgâr hızı ve yönü olarak sayılabilir. Kullanılan GPS alıcısı ile YKN'lerin gerçek koordinatları elde edilebiliyorsa bu durumda yalnızca konumsal hassasiyet değil aynı zamanda konumsal doğruluk analizi de yapılabilecektir. Çalışmada da belirtildiği gibi yüksek hassasiyete sahip bir ortomozaik üretilmek isteniyorsa çalışma alanının fiziksel sınırları ötesinde bir alanda uçuşun gerçekleştirilmesi önerilmektedir (Hung ve ark 2019).

Hedef veya olay tespiti, drone ağlarının ana uygulamalarından biridir. Hedefin arama süresini en aza indirmek veya algılama olasılığını en üst düzeye çıkarmak olan İHA ekipleri için çeşitli ortak arama algoritmaları bir çalışmada önerilmiştir. Bu çalışmalarda bağlantı genellikle işbirliğini sağlamada bir kısıt olarak kabul edilmektedir. Bir çalışmada, İHA ağlarındaki hedef algılama sorununa hem algılama hem de bağlantı bakış açılarından yaklaşılmaktadır. Amaç sadece sabit bir hedef bulmak değil, aynı zamanda yer personeli çok hedefli bir iletişim zinciri üzerindeki hedefin durumu hakkında bilgilendirmektir. Kapsam tabanlı ve bağlantı tabanlı yol planlama algoritmaların performansını olasılık ve algılama zamanı ile bildirim açısından analiz edilmiştir. Kapsam ve bağlantı arasında bir denge olduğunu ve sınırlı sayıda drone ile başarılı görev tamamlama için her iki yönünde dikkate alınması gerektiği belirlenmiştir (Adam 2019)

Son dönemlerde yapılan araştırmaların İHA çerçevesinde oluşturduğu en önemli başlıklardan biri “uygun İHA tercihi” olarak görülmektedir. Bu başlık, özellikle kullanıcılar

için kolaylık oluşturan İHA araştırmalarında çok sık karşılaşılır bir konu olmuştur (Samad ve ark 2013, Verheyden ve ark 2019). Uygun İHA ile yapılan çalışmalara farklılık kazandırmak için yapılan çalışmada termal kamera, çok bantlı kamera gibi pahalı donanımların kullanılmadığı durumlarda klasik RGB kameralar ile üretilebilecek çeşitli harita tipleri araştırılmıştır. Sonuç olarak RGB kamera görüntülerinden bant çeşitlendirmeleriyle ıslak-kuru vejetasyon tespiti yapılmış, kıyı çizgilerinin belirlenebildiği gösterilmiştir (Komarkova ve ark 2019). Farklı amaçlarla kullanılan İHA sistemlerinde de sonuç ürünlerin yüksek doğruluk verdiği belirlenmiştir. Gaziosmanpaşa Üniversitesi, Tokat, kampüs alanında yapılan çalışmada araştırmacılar yüksek hızlı hareket eden bir yer kaymasının İHA ile tespitinin mümkün olduğunu bulmuştur. Sonuçlar, karesel ortalama hata (KOH) 3.3 cm olduğunu göstermiş ve 37.3 cm boyutunda bir hareketi belgelemiştir (Yıldırım ve ark 2016).

İHA uçuş süresi maksimizasyonu çok önemli bir konudur. Dört giriş parametresine (elektronik hız kontrol –EHK-) ünitesi sinyali, fırçasız motorun dakikadaki dönüş sayısı (DDS), pervanenin çapı ve hatvesi) ve üç çıkış parametresine (gerekli itki kuvveti, uçuş süresi ve motor verimliliği) dayanan bir model ile uçuş süresi optimizasyonu yapılmıştır. Çalışmada yetmiş beş adet veriden faydalanılmış ve YSA'nın eğitiminde, tanjant sigmoid (tansig), logaritmik sigmoid (logsig) ve lineer (purelin) aktivasyon fonksiyonları ara katman ve çıkış katmanları için kullanılmıştır. Tahmin sonuçlarını değerlendirmek için de Karesel Ortalama Hata (KOH) değeri kullanılmıştır. Sonuçta farklı olasılıkların, daha az maliyet ve zaman kaybıyla değerlendirilmesinde etkin bir şekilde kullanılabileceğini göstermiştir. Böylece, farklı özelliklerdeki İHA problemlerinin çözümünde, önerilen yöntemin, mevcut yöntemlere alternatif olarak faydalanabileceği ortaya konulmuştur (Konar 2019).

Hava taşıtlarının tasarımlarının daha verimli olması, ürün kalite ve performanslarının geliştirilebilmesi amacıyla YSA ile kombine edilen stokastik çok nesneli optimizasyon sistemi ve bu sistemin hava taşıtlarının biçimlerinin aerodinamik şekilleri için uygulaması yapılmıştır. Aynı problemi sadece MOPSO tekniği ile gerçekleştirince ve yapay sinir ağları ile kombine edilmiş MOPSO (ANN-MOPSO) tekniği ile gerçekleştirince ortaya çıkan sonuçlar hesap süresi ve en optimal çözümü bulma açısından incelenmiş ve karşılaştırılmıştır. Sonuç olarak, yapay sinir ağları eklenmiş 3000 değerlendirmeye sahip ANN-MOPSO, 5500 değerlendirmeli olan MOPSO sistemine kıyasla %33 daha az hesaplama süresi ile çok daha fazla sayıda geçerli çözüm üretmiştir. Ayrıca sürekli eğitimin (continuous training), aerodinamik şekil dizaynı optimizasyon problemi için hesaplama süresi ve çözüm kalitesini açısından etkili bir yaklaşım olduğu görülmüştür (Azabi ve ark 2019).

Çoklu etkileşimli ya da sürü olarak adlandırılan İHA'lar için temel modelleme ve simülasyon teknikleri sağlamak ve bilgi toplama işlemlerini optimize etmek için temel makine öğrenimi algoritmalarının uygulanmasını incelenen araştırma gerçekleştirilmiştir (Behnck ve ark 2015, Martin ve ark 2016, Durdu ve ark 2019). Yapılan bir çalışmada amaç sürülerin yol planlamasının doğrudan simülasyonu için nispeten basit mekanik modeller ve hızlı sayısal çözüm stratejileri geliştirmektir. Çalışmada sürü İHA'ların enerji tüketimi, afetlere yapılacak müdahaleler gibi hususlar bakımından yol planlamasının önemi vurgulanmıştır (Zohdi 2020). Başka bir çalışmada ise nehir yataklarında bulunan parçacıkları boyutunu belirlemek için klasik yöntemler, kısa vadede birçok büyük alanları manuel olarak araştırmanın ve konumsal dağılımı hakkında bilgi edinmenin zorluğunu barındırmaktadır. Bu zorluklarla başa çıkmak için, görüntü işleme teknikleri veya yüksek çözünürlüklü topografik verileri kullanmanın etkin bir yöntem olduğu belirtilmiştir. Bununla birlikte, parçacık boyutları, şekiller ve paketleme yapılarının aralığı, bu yöntemlerin uygulanabilirliğini sınırlamaktadır. Yapılan bir çalışmada İHA'lardan çakıl ve kumun parçacık boyutunu tahmin etmek için YSA modeli önerilmiştir. İHA görüntüleri ve SAM, gelişmiş tahmin doğruluğu ile modele çözüm olmaktadır. Çalışmada önerilen YSA modelleri, nehir yatağı parçacıklarının çapını yaklaşık $-0,7$ mm ortalama hata ve yaklaşık $16,3$ mm ortalama standart sapma ile tahmin etmiştir (Takeuchi ve Nakanishi 2019).

İHA görüntülerinden yapılan çalışmada, yüksek konumsal çözünürlüklü renkli (Kırmızı, Yeşil, Mavi) stereo İHA görüntülerinden kentsel alanlarda sabit araçların tespiti yapılması için ilk adımında stereo İHA görüntülerinden Sayısal Yükseklik Modeli (SYM) sonra, SYM verisinden SAM üretilmiştir ardından normalize yüzey; SYM ve SAM verilerinin farkı alınarak (nSYM) üretilmiştir. Daha sonra, elde edilen nSYM verisi ek bant olarak kullanılmak suretiyle ortofotonun çoklu çözünürlük segmentasyonu ve ardından nesne-tabanlı sınıflandırması yapılmaktadır. Sonuç olarak araç tespiti doğruluğu birinci test alanı (Alan#1) için %78.53 ve ikinci test alanı (Alan#2) için %92.15 olarak bulunmuş ve İHA görüntülerinden yüksek tespit yapılabildiği gösterilmiştir. SAM'lerde sistematik kubbe (dome) hatasının azaltılması için daha iyi bir uçuş tasarımının etkisini araştırmak için dikey, yakınsak, ilgi noktası (POI), çok boyutlu ve karışık görüntüler dâhil olmak üzere toplam 22 uçuş tasarımı test edilmiştir. Uçuşlar, 143 yer noktasının tesis edildiği 300×70 m² düz test sahası alanında gerçekleştirilmiştir. Toplamda 396 farklı test olmak üzere üç farklı İHA ve iki ticari yazılım paketi denenmiştir. Araştırmacılar POI uçuş tasarımını kullanarak, SAM'lerin doğruluğunun, daha fazla yer kontrolü veya pahalı RTK / PPK sistemleri kullanmaya gerek kalmadan artacağını belirtmişlerdir (Forlani ve ark 2018, Inal ve ark 2018, Sanz-Ablanedo ve ark 2020).

Doğal felaketlerin yıkıcı etkileri ile baş edebilmek için optimizasyon yöntemleri önerilmektedir. Felaket senaryolarında uygulama süresinin sıkı bir biçimde yönetilmesi gerektiği için, özellikle gelişmiş optimizasyon tekniklerini kullanarak, kablosuz ağ sensörlerinde (WSNs) gömülü röle destekli İHA'ların doğal felaketlerin yıkıcı etkileri ile baş edebilmeleri için etkili optimizasyon yöntemleri önerilmiştir. Bu model, sensor verisini izleme ve toplama için İHA-WSN iletişimine gömülü gerçek zamanlı optimizasyonu kullanmaktadır. Problemi milisaniyelerde çözmek için hızlı yayılması gereken İHA tabanlı optimizasyon için sınırlandırılmış K-means kümeleme metodu önerilmektedir (Duong ve ark 2019).

İHA ile farklı uçuş görevleri sırasında ve farklı operasyon koşullarında elde edilen ve İHA konumlarını ölçebilecek bir deneysel bir test bölgesiyle çeşitli hava koşullarında farklı İHA'lar için test prosedürü geliştirilmiş ve test edilmiştir. Yapılan bir çalışmada, tasarım verileri ve İHA'nın dâhili belleğine kaydedilen verilerle karşılaştırmalı olarak, bir robotik toplam istasyon kullanılarak gerçekleştirilen İHA'nın uçuş yörüngesinin ölçümlerini açıklayarak ve analiz ederek beş farklı test görevi yapılmıştır. Elde edilen sonuçlar, tasarımla karşılaştırıldığında görev performansının doğruluğunun değerlendirilmesine ve tüm İHA setinin uçuş doğruluğunun belirlenmesine olanak sağladığı görülmüştür. Kalkış ve inişleri optimize eden algoritmaları, nesneler için yapılan test uçuşlarını ve ayrıca uçuş gerekliliklerini evrensel bir düzeyde araştıran çalışmada İHA'ları kullanırken uçuşların güvenliğini artıracak çeşitli arazi ve hava koşullarında planlama yapma kolaylığı sunmaktadır. Araştırmaların daha önce hiç yayınlanmamış araştırmaları gösterdiği belirtilmiştir. Bu tür bir görevin uygulanması, İHA uçuşlarının gerçek irtifasının kontrol edilmesini sağladığı söylenmektedir. Elde edilen sonuçlar ve U-Uzayının kurulması ile ilgili planlanan İHA kullanım kuralları dikkate alınırken, uçuşların 120 m'ye kadar olan irtifalarda gerçekleştiği varsayılmış ve GNNS-IMU cihazlarının doğruluk açısından test edilmesi gerektiği belirtilmiştir (Ćwiakała 2019).

İHA'lar ile oluşturulan gözetim sistemleri için optimal yol planlaması ve kargaşa önleme kontrolü araştırılan çalışmada, bağlayıcı K-kümeleme metodu öneren bir küme, 3B gerçek pilot uçuş şekillerinden dizayn edilmiş optimal yol planı şemasının maliyet fonksiyonu olması için eğitilmiş ve test edilmiş enerji tüketim regresyon modeli kullanılmıştır. A-star ve uygun ağırlıklandırmayla “Set-Based Particle-Swarm-Optimization” (S-PSO) algoritması denenmiştir. Ayrıca çeşitli öğrenme oranları ile çevrimiçi bir adapte olabilen YSA kontrolcüsü, kontrol sabitliğinden emin olmak için tasarlanmıştır. Önerilen sistemin etkisi sayısal simülasyonlar ve deney sonuçları ile doğrulanmış olup gerçek pilot uçuşundaki ortalama tüketilen enerji 96.593 Wh iken önerilen en uygun yol planı şemasının kullanılmasıyla enerji tüketimi 72.3397 Wh olmuştur. Dış bozuklukları varlığı durumunda, oransal bir integral fark

kontrolü (PID) ve bulanık kontrol sistemine karşın önerilen adapte olabilen sinir ağı kontrolü sistemi karesel ortalama hatayı hem düşeyde (37.5%) hem de yatayda (49.083%) iyileştirmiştir (Wai ve Prasetia 2019). İHA'ların uçuş sırasında yapısal sağlıklarının izlenmesi için yapısal sağlık izleme tasarımı yapılmış ve uçuş esnasında yapısal hareketlerin incelenmesi için İHA'nın arka gövdesinde FOS ve PZT sensörleri kullanılmıştır. Veri işleme için de YSA algoritmaları kullanılmıştır. Çalışmada farklı sensörlerle, sinir ağlarının avantajlı ve dezavantajlı yönleri ve YSA eğitiminin hasar tespitindeki potansiyeli araştırılmıştır (del Río Velilla ve ark 2019).

İHA'lar ile ilgili geliştirilen optimizasyon modellerin bir çoğu en uygun uçuş ağı planlamasına dayanmaktadır (Zhang ve ark 2010, Arantes ve ark 2016, Zhang ve ark 2016, Cho ve ark 2018, Radmanesh ve ark 2018, Coombes ve ark 2019, Dewangan ve ark 2019, Duong ve ark 2019, Wai ve Prasetia 2019, Zohdi 2020). Genetik algoritma, gri kurt algoritması, karınca kolonileri, ESA ve ajan bazlı makine öğrenmesi metotları gibi farklı optimizasyon modellerinin kullanıldığı bu çalışmalar başlangıçta yapılacak çalışmanın oluşturması gereken farklılıkları belirlemek açısından yardımcı olmuştur. Çoklu İHA için uçuş ağı optimizasyonu (Zohdi 2020), ESA ile enerji tüketimi tahmini optimizasyonu (Wai ve Prasetia 2019), çoklu İHA'lar için rüzgâr direnci optimizasyonu (Cho ve ark 2018) gibi çalışmaları da göz önünde bulundurarak yapılması gerekenler belirlenmiştir. Özellikle yapay zeka algoritmalarının İHA kullanımında tercih edildiği literatür çalışmalarına göre bulguların tatmin edici sonuçlarının fotogrametrik uçuş planlaması parametrelerine uygulanabilirliği görülmüştür. Fotogrametrik uçuş parametrelerinin optimizasyonunun alanında yapılan literatür araştırmasında denk gelen benzer bir çalışma bulunamadığı için bu çalışmanın bir örnek çalışma olacağı ve gelecek çalışmalara referans olabileceği düşünülmüştür. Bu amaçla materyal olarak tercih edilen İHA'lar (sabit kanatlı - döner kanatlı) farklı uçuş özelliklerinde ve farklı çalışma alanlarında uçurulmuş ve ardından sonuçlar belirlenmiştir.

3. MATERYAL VE YÖNTEM

Bu bölümde çalışmanın uygulamalarının yapıldığı alanlar; çalışma alanlarında homojen dağıtılmış ve işaretlemeleri gerçekleştirilmiş YKN'ler (yeryüzünde tesis edilen, koordinatları ve/veya yüksekliği jeodezik yöntemlerle belirlenen noktalar) ve gerekli uçuşların yapılması için kullanılan sabit kanatlı İHA ve döner kanatlı İHA'lar tanımlandı. Ayrıca koordinatların GNSS alıcısı ile belirlenmesi için kullanılan CORS ve RTK yöntemleri, optimizasyonda kullanılan algoritmaların matematiksel modelleri ve GUI için tercih edilen yazılımlar bu bölümde açıklandı.

3.1. Kullanılan İHA'lar

İHA sistemlerini genel olarak ikiye ayırmak mümkündür. Bunlar; sabit kanatlı İHA ve döner kanatlı İHA olarak tanımlanır. Değişik üretim amaçları olan bu İHA tiplerinin birbirlerine karşı bir takım üstün ve zayıf tarafları bulunmaktadır (Fahlstrom ve Gleason 2012). Genel olarak doğrudan konumlandırma ile çalışmaktadırlar. Doğrudan konumlandırma, görüntüleri yer-referanslı olarak kayıt eder. Doğrudan yer-referanslama ile YKN kullanmaksızın, görüntüler alım anında GNSS-IMU ile kaydedilen izdüşüm merkezlerinin konum ve dönüklüklerini kullanarak dış yöneltme parametrelerinin hesaplanmasıdır. GNSS-IMU sistemi ise görüntü alımı sırasında görüntünün izdüşüm merkezinin üç boyutlu koordinatlarını ve üç eksenindeki dönüklüklerini hesaplayan sistemdir (Austin 2011, Fahlstrom ve Gleason 2012). Sivil Havacılık Genel Müdürlüğü (SHGM) tarafından yayınlanan İHA talimatnamesi SHT-İHA'ya göre azami kalkış ağırlığı 500 gr (dâhil) – 4kg aralığında olan İHA'lar sınıf olarak İHA 0 sınıfında kabul edilmektedir. Çalışmada kullanılan Sabit kanatlı İHA ve döner kanatlı İHA (Çizelge 3.1 ve Çizelge 3.2) İHA 0 sınıfındadır. Çalışmada kullanılan döner kanatlı İHA Parrot ANAFI ise SHT-İHA talimatnamesine göre oyuncak sınıfında olup kullanılması için herhangi bir yetenek ve bilgi gerektirmemektedir (Çizelge 3.3).

3.1.1. Sabit kanatlı İHA

Sabit kanatlı İHA, motor-rotor sistemlerinin arkada olduğu ve bir platformdan ya da el ile fırlatılması gereken sistemlerdir. Bu sistemlerin yapısı itibariyle en önemli özelliği havada süzülecek bir aerodinamik yapıya sahip olmalarıdır. Kuşların yapılarından ve büyük uçaklardan ilham alınarak tasarlanan İHA, havada daha uzun süre kalmayı sağlayan bir sonuç ortaya çıkarır (Şahin ve Oktay 2019). Uzun süre havada kalabilmesine rağmen, dikine iniş kalkış

yeteneklerinin kısıtlı olması sabit kanatlı İHA'ların önemli bir dezavantajı olarak görülmektedir (Güçlü ve ark 2016, Şahin ve Oktay 2019). Bu çalışma süresince sabit kanatlı İHA olarak kullanılan SenseFly Ebee+ RTK (Şekil 3.1) harita mühendisleri tarafından özellikle tercih edilmektedir. Uzun süreli havada kalma yeteneği onu çok geniş alanlarda yüksek çözünürlük açısından önemli bir noktada konumlamaktadır. Özellikleri açısından genel endüstriyel standartlara sahip olması (Çizelge 3.1) ve harita mühendisleri tarafından tercih edilen Gerçek Zamanlı Kinematik (GZK) (Real Time Kinematic –RTK-) özelliğini barındırması açısından küresel olarak talep gören bir İHA olarak görülmektedir (Tsai ve Lin 2017).

Çizelge 3.1. SenseFly Ebee RTK + özellikleri

Kanat açıklığı:	110 cm
Ağırlık:	1.1 kg
Maksimum iletim aralığı:	3 km
Maksimum uçuş süresi:	59 dk
Maksimum yatay hız:	30 m/sn
Maksimum düşey hız:	11 m/sn
Maksimum rüzgâr direnci:	13 m/sn



Şekil 3.1. Sabit kanatlı İHA (Ebee RTK+ sabit kanatlı İHA)

3.1.2. Döner kanatlı İHA'lar

Günümüzde kullanıcıların daha çok tercih ettiği tip olan döner kanatlı İHA sistemleri, maliyeti ve kullanım kolaylığı açısından daha ön plana çıkmaktadır. Özellikle DJI firmasının endüstriyel ürünleri hem kullanım kolaylığı hem de fiyat uygunluğu açısından çok tercih edilmektedir. Uçuş sürelerinin düşük olması, kameralarının genellikle sabit ve düşük çözünürlükte olması gibi bazı durumlar ise döner kanatlı İHA sistemlerinin negatif tarafları olarak görülmektedir. (Güçlü ve ark 2016). Çalışmalarda kullanılan DJI Phantom 4 Pro modeli (Şekil 3.2) firmanın en popüler modellerinden biri olmuştur. Özellikleri (Çizelge 3.2) açısından gayet tatminkâr olan bu model fiyat olarak da uygun görülmektedir.

Çizelge 3.2. DJI Phantom 4 Pro özellikleri

Katlanmış boyut:	290 × 290 × 196 mm
Ağırlık:	1375 g
Maksimum iletim aralığı:	7 km
Maksimum uçuş süresi:	30 dk
Maksimum yatay hız:	12 m/sn
Maksimum düşey hız:	3 m/sn
Maksimum rüzgâr direnci:	17 m/sn



Şekil 3.2. Döner kanatlı İHA (DJI Phantom 4 Pro döner kanatlı İHA)

Bu çalışmada kullanılan diğer bir döner kanatlı İHA ise Parrot firmasının ANAFI modelidir (Şekil 3.3). Özellikleri (Çizelge 3.3) genel olarak sıradan gibi görünse de kameranin 180° hareket kabiliyeti ve yüksek rüzgâr direnci İHA'yı özel bir yere taşır.

Çizelge 3.3. Parrot ANAFI özellikleri

Katlanmış boyut:	175 x 240 x 65 mm
Ağırlık:	320 g
Maksimum iletim aralığı:	4 km
Maksimum uçuş süresi:	25 dk
Maksimum yatay hız:	15 m/sn
Maksimum düşey hız:	4 m/sn
Maksimum rüzgâr direnci:	14 m/sn



Şekil 3.3. Döner kanatlı İHA (ANAFI Parrot döner kanatlı İHA)

3.2. Çalışma Bölgeleri


Bu çalışma kapsamında seçilen test sahaları, farklı karakteristik jeomorfolojik özelliklere sahip olup değişik eğimlerde arazi yapısına sahiptir. Konya ili sınırlarında yer alan merkez Selçuklu ilçesi ve Karapınar ilçesi sınırlarında bulunan test bölgeleri, kentsel alan, kırsal alan,

tarımsal alan gibi arazi tiplerini kapsamaktadır. Uygulama yapılan araziler eğim tipi olarak, düz arazi, eğimli arazi ve çok eğimli arazi bölgelerinin tamamını kapsamaktadır. Çizelge 4.1, Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4'te gösterilen değerler Test Alanı A ve B'de yapılan sonuçların elde edildiği test alanlarıdır.




Şekil 3.4. Test Alanı A

Konya ili, Karapınar ilçesi sınırlarından yer alan Han Çukuru Bölgesi (Şekil 3.4); arazi yapısı tamamen bitkisel yaşamdan bağımsız, çorak ve eğimli bir alandır. Düz alan, orta eğimli alan ve yüksek eğimli alan içermektedir. Bölgede toplamda 50 adet Yer Kontrol Noktası (YKN) oluşturulmuştur. Ayrıca sabit kanatlı ve döner kanatlı uçuşlarının birlikte yapıldığı bir bölgedir.



Şekil 3.5. Test Alanı A – B

Konya ili, Karapınar ilçesi sınırlarından yer alan farklı bölgeler; tarımsal alan, kırsal yerleşim alanı özellikleri barındırmaktadırlar (Şekil 3.5). Bölge özellikle tarım olmayan düzlüklerde çölleşmenin görüldüğü ve model üretmek için farklı zorluklar gösteren bir bölgedir. Tarımsal alanların geneli buğday, şeker pancarı, mısır, arpa vb. İç Anadolu Bölgesi'nin çoğunluğunda tercih edilen tarım ürünleridir. Arazi genel olarak tarımsal ürünler yetiştirilen ve eğim ortalaması çok düşük olan bir yapıya sahip olmakla birlikte farklı bir doğal form olarak obruklar da arazide sıklıkla görülmektedir.




Şekil 3.6. Test Alanı C; aşkının yaylası höyüğü c1, sırçan höyük c2, gökgöz höyüğü c3

Bir başka test bölgesi ise Konya İli sınırlarında yer alan Gökgöz Tepesi Höyüğü (c3), Sırçan Höyük (c2) ve Aşkının Yaylası Örenyeri (c1) olarak höyüklerine ait uçuşların yapıldığı bölgedir (Şekil 3.6). Bu alanların temel ortak özellikleri ise eski tunç dönemi, antik dönem, roma dönemi ve yakın geçmiş gibi birçok farklı döneme ait kalıntılar barındırmasıdır. Ayrıca bu höyüklerde yıllarca yapılmış olan birtakım tarımsal faaliyetler ve kaçak kazılar bu höyüklerin bir kısmının tahrip olmasına sebep olmuştur. Yapılan çalışmalarda bu höyüklerin barındırdığı yüksek kalıntı miktarı höyüklerin önemini belgelemektedir. Çizelge 4.4'te gösterilen değerler Test Alanı C'de yapılan sonuçların elde edildiği test alanıdır.



Şekil 3.7. Kampüs bölgesi (Test Alanı D)

Konya ili, Selçuklu ilçesi sınırlarında bulunan Selçuk Üniversitesi Alâeddin Keykubat Yerleşkesi Kampüs Alanı; düz alan, orta eğimli alan ve yüksek eğimli alan içermektedir (Şekil 3.7). Ayrıca yerleşke içerisinde, bitki yetiştirme ve ıslah alanı, cami, fakülte çevre yolu, konutlar ve farklı binaları içeren bölgeler de yer almaktadır. Uçuşların büyük çoğunluğu bu bölgede yapılmış olup, uçuş önceleri toplam 188 adet YKN bölgede homojen olarak işaretlenmiştir. Çizelge 4.5 ve Çizelge 4.6’da gösterilen değerler Test Alanı D’de yapılan sonuçların elde edildiği test alanıdır.



Şekil 3.8. Karma alan (Test Alanı E)

Son test alanı olarak ise belirlenen alan ise karma bir alan olan (vadi, kırsal alan, düz alan, eğimli alan ve çok eğimli alan içeren bir bölge) Şekil 3.8’te görülen bölgedir. Konya İli Selçuk Üniversitesi Kampüsü ile Konya Teknik Üniversitesi için belirlenen yeni kampüs yerleşkesi arasında kalan ~275 hektarlık bir bölge farklı arazi yapılarını barındırmaktadır. Çizelge 4.7’de gösterilen değerler Test Alanı E’de yapılan sonuçların elde edildiği test alanıdır.

3.3. Hava Fotogrametrisi İş Akışı

Dijital fotogrametri hava fotogrametrisi iş akışı şu şekildedir gerçekleşmektedir (Şekil 3.9):

- Hava görüntüsü alımı için gerekli YKN’lerin planlanması ve arazide tesisi edilmesi gerçekleştirilir.

- Bilgisayar ortamında otomatik uçuş planı yazılımları programı ile uçuş için gerekli kolon hatlarının grafik olarak tasarlanması ve blokların oluşturulması tamamlanır.
- Uçuş planına uygun olarak uçuşun yapılır ve görüntülerin alımı yapılır.
- Kinematik GNSS/IMU verileri fotogrametrik nirengi ve blok dengeleme işlemine aktarılır.
- Fotogrametrik nirengi ve dengeleme işlemi için yazılıma; dilim numarası, dilim orta meridyeni, ölçek faktörü vb. parametreler ve uygun projeksiyon sistemi tanımlanır.
- Belirli bir sabit baz mesafesine sahip metrik kamera (Odak uzaklığı, görüntülemeadaki piksel boyutları, yatay ve düşey doğrultudaki piksel sayıları bilinen hava kameraları) ile çekilmiş görüntü çiftleri yazılımlara aktararak kütüphaneden otomatik kalibre edilir (Uysal 2018, Chen ve Pan 2020).
- Kamera parametreleri tanımlanmış görüntü çifti, eğer ölçmeleri yapılmışsa YKN koordinatları ile her bir görüntünün GNSS/IMU parametreleri de kullanılan yazılıma tanıtılır.
- Klasik, kinematik GNSS destekli veya kinematik GNSS-IMU destekli olacak şekilde YKN ve görüntülerin bağlama noktaları yardımıyla dış yöneltme parametrelerinin hesaplanması (fotogrametrik nirengi) ve fotogrametrik nirengi blok dengeleme işlemleri tamamlandıktan sonra stereo görüntüler oluşturulur model üretmeye hazır hale gelir.
- Eğer hazır SAM varsa ise altlık olarak kullanarak, yok ise otomatik veya yarı otomatik yöntemlerle SAM üreterek stereo görüntü ile bir araya getirilir.
- Bu şekilde tamamlanan sürecin sonunda görüntülere uygulanan ortorektifikasyon (arazi şeklinden dolayı oluşan kayıklıkların giderilmesi) ve vektörizasyon işlemleri gerçekleştirilerek ortofoto harita veya ortomozaik harita üretilmiş olur (Ünal ve Yıldız 2020).

Üretilen ortofoto doğruluğu kameranin çözünürlüğüne, kameranin odak uzaklığına, YKN'lerin işaretleme kalitesine ve koordinat doğruluğuna, fotogrametrik nirengi ölçme ve blok dengelemenin doğruluğuna, sonuç piksellerin boyutuna, radyometrik düzeltmeye, denetleme noktalarının seçimine ve SAM verilerinin doğruluğuna bağlıdır (Egels 2001, Linder 2009, Fahlstrom ve Gleason 2012, Özemir ve Uzar 2016, Öztürk ve ark 2017, Tsai ve Lin 2017, Barba ve ark 2019, Tjahjadi ve ark 2019, Chen ve Pan 2020).



Şekil 3.9. Hava fotogrametrisi iş akış diyagramı

3.3.1. Hava fotogrametrisi uçuş planlaması

Hava fotogrametrisinde sayısal görüntü alımı geleneksel fotogrametrik uçuş planlamasındaki temel prensiplerle benzerdir. Geleneksel uçuş planı ise; uçuş doğrultusuna, üretilecek haritanın kullanım amacı ve üretilecek harita ölçeğine, kamera özelliklerine, uçağın teknik kapasitesine, mevsim ve meteorolojik etkenler gibi parametrelere bağlıdır (Egels 2001, Linder 2009, Uysal 2018). Uçuş planlamasının seçiminde:

- Topografyanın jeomorfolojik özellikleri (Manconi ve ark 2019, Song ve ark 2019),
- Proje yapılacak sahanın bölgesel özellikleri (deniz, göl vb suyla kaplı alanlar olup olmama veya ülke sınırlarına yakın olma olmama gibi),
- Harita sahasının geometrisi,
- Projenin amacı (koridor haritalama, kentsel alan haritalama vb.),
- Atmosferik koşullar (rüzgâr, sıcaklık, basınç ve nem gibi),
- Kullanılacak kamera türü, GNSS ve IMU cihazlarının teknik özellikleri ve
- Yürürlükteki teknik mevzuatın öngördüğü doğruluklar göz önünde bulundurulur.

Blok (birden fazla kolondan oluşan görüntüler dizisi) hazırlamak için ve kolon sayılarının konumlarının belirlenmesi için yapılacak uçuş planı, haritası yapılacak bölgede (proje sahasında) uçuştan önce hazırlanan bölgeye ait 1/25000 gibi ölçekli haritalar, büyük ölçekli görüntüler ya da uydu görüntüleri üzerinde planlanan bir ön çalışmadır. Burada bahsedilen “Kolon” aynı yükseklikte ve aynı doğrultuda peşi sıra çekilmiş görüntüler dizisidir. Hava fotogrametrisinde görüntü alımı yapılırken havanın bulutsuz olması ve güneşli olması, arazinin karla kaplı olmaması gerekmektedir. Ayrıca metrik kamera kullanılması ve uçuş planlamasının profesyonelce hazırlanması gerekmektedir. Hava fotogrametrisi iş akışı (Şekil 3.10) belirlenirken görüntü ölçeği, harita ölçeği, kolon sayısı, uçuş yönü, bindirme oranları, uçuş eksen, baz uzunluğu ve atmosferik koşulların tamamı hesaba katılmalıdır. Fotogrametrik amaçlı yapılan uçuşlar Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği (BÖHHBÜY-2018) uyarınca aşağıdaki maddeye dayanarak yapılmalıdır:

“MADDE 51- (2) Fotogrametrik yöntemlerin uygulanmasında kullanılan YKN bu Yönetmelikte belirtilen esaslar çerçevesinde en az C3 derece ağ özelliğinde tesis edilir, ölçülür ve hesaplanır.

(3) Fotogrametrik yöntemlerde kullanılacak görüntüler metrik hava kameraları ile çekilmelidir. Alınan görüntülerin yöneltme işlemlerinde klasik, Kinematik-GNSS destekli veya olanak var ise GNSS-IMU destekli fotogrametrik nirengi yöntemleri kullanılabilir.


(4) Ülke sınırına olan en uzak mesafesi 15 km'yi geçmeyen alanlarda gerçekleştirilmelidir.

Ayrıca görüntülerin çekimi de BÖHHBÜY 2018 Madde 57'ye göre yapılmalıdır. Bu madde aşağıdaki gibidir:

“(1) Uçuş görevi, Nisan ayının başı ile Ekim ayının sonu arasındaki dönemde uçuş planına uygun olarak bulutsuz bir havada, yerel öğle zamanından yaklaşık iki saat önceki ve sonraki zaman aralığında gerçekleştirilir.

(2) Görüntü alımının planlanan biçimde gerçekleştirilmesi için GNSS denetimli uçuş sisteminden de yararlanılır. Görüntü alım noktalarının planlanan durumdan olan farkları görüntü ölçeğinde 1 cm'yi geçmemelidir. Kamera ekseninin düşey doğrultudan sapmaları da 5°'yi geçmemelidir.”





Şekil 3.10. Hava fotogrametrisi uçuş planlaması aşamaları

3.3.2. Fotogrametrik İHA kullanımı için temel görüntü alımı


Ülkemizde yürürlükte olan BÖHHBÜY en son sürümü de dâhil olmak üzere henüz İHA için belirli bir kısım veya madde içermemektedir. Ayrıca İHA'lar fotogrametrik olarak literatürde kendine tam karşılık bulamamaktadır. İş akışı da bu sebepten ötürü net bir şekilde tanımlanamamakla birlikte belirli standartlarda gerçekleşmektedir. Görüntünün daha verimli

kullanılması ve daha fayda sağlanabilmesi için literatürde karşılaşılan genel kabul olarak varsayılan belirli standartlar oluşmuştur. Bu standartların temeli ileri ve yan bindirme oranlarının genel olarak yüksek belirlenmesi, rüzgâr koşullarına ve yasal zorunluluklara göre uçuş yüksekliğinin maksimum seçilmesi ve görüntüsü alınacak alan tipine göre arazi koşullarının hesaba katılarak farklı planlamaların tercih edilmesi olarak söylenebilir (Fahlstrom ve Gleason 2012, Cryderman ve ark 2014, Özemir ve Uzar 2016, Öztürk ve ark 2017, Barba ve ark 2019, Ayyildiz 2020).

3.3.2.1. İHA fotogrametrisi iş akışı

Ormanları, karlı alanları, büyük su kütlelerini, geniş tarım alanlarını ve/veya 3B model elde edilmesi zor olan diğer alanları içermeyen projeler genel görüntü alımına konu olarak kabul edilmektedir. Genel görüntü alımı için önerilen bindirme oranları en az % 75 ileri bindirme ve en az % 60 yan bindirme olarak kabul edilir. Görüntülerin düzenli bir grid deseni ile alınması önerilir (Şekil 3.11). İstenen YÖA sağlamak için kamera, arazi/nesne (obje) üzerinde olabildiğince sabit bir yükseklikte tutulmalıdır (Linder 2009, Özemir ve Uzar 2016, Öztürk ve ark 2017, Barba ve ark 2019). Ayrıca Geometrik ve radyometrik doğruluk olarak en iyi ortomozaik elde edilebilmesi için;

- Seçilen uçuş yönü (Hernandez-Lopez ve ark 2013, Rojas 2014, Manconi ve ark 2019),
- GNSS alıcısının doğruluğu,
- Kamera çözünürlüğü (Roth ve ark 2018, Domingo ve ark 2019) ve
- Uçuş esnasındaki rüzgâr şiddeti (Cho ve ark 2018, Coombes ve ark 2019) parametrelerine dikkat edilmelidir.



Şekil 3.11. Görüntü alımı temel kavramları

3.3.2.2. Uçuş yüksekliğinin (Yer Örnekleme Aralığı) ve ileri/yan bindirme oranlarının hesaplanması

Yer Örnekleme Aralığı (YÖA), zemindeki ardışık iki pikselin merkezleri arasındaki mesafedir (Egels 2001, Linder 2009). Aynı zamanda görüntüdeki bir pikselin yeryüzü üzerindeki karşılığıdır olarak da ifade edilmektedir. Üretilen model sonuçların doğruluğunu, kalitesini ve sonuç ürün ortomozaikte görünen detayları etkiler (Şekil 3.12).

Hedeflenen YÖA'yı elde etmek için uçuş yüksekliği (H) hesaplanabilir ve bu değer kamera odak uzaklığına (f), kamera sensörü genişliğine [mm] ve görüntü çerçevesinin genişliğine [piksel] bağlıdır (S_g : sensör genişliği [mm], f: odak uzaklığı [mm], H: uçuş yüksekliği [m]). Bir görüntünün uçuş yönünde (görüntü çerçevesinin kısa kenarı) arazide kapladığı mesafe AG_g [m] ve bir görüntünün uçuş yönünde çerçeve genişliği $\mathcal{C}_g$ [piksel] olmak üzere (Egels 2001, Linder 2009):

$$H / f = \zeta_g / S_g ; H = (\zeta_g * f) / S_g;$$

$$AG_g = (\zeta_g * Y\ddot{O}A) / 100 \quad (3.1)$$


Denklemleri ile bulunur. Uçuş yüksekliği ise (H) Denklem 3.2 ile elde edilir.

$$H = (AG_g * f) / S_g \quad (3.2)$$

Yer Örnekleme Aralığı; istenen YÖA [cm/piksel] olmak üzere Denklemleri (3.1) ve (3.2) birleştirilerek, uçuş yüksekliği şu şekilde hesaplanır (Şekil 3.11).


$$H [m] = (\zeta_g * Y\ddot{O}A * f) / (S_g * 100) \quad (3.3)$$





Şekil 3.12. Uçuş planlaması parametrelerinin gösterimi

Uçuş planlaması sırasında, ileri bindirme oranı belirlemek için, İHA'nın zemine göre hızına (v), YÖA'ya ve kameranın piksel çözünürlüğüne göre hesap yapılmalıdır.



Şekil 3.13. İleri bindirme oranı baz mesafesinin gösterimi

İleri Bindirme (B_b): uçuş yönündeki iki görüntü arasındaki ileri yönlü bindirme [m], Baz (b): uçuş yönündeki iki görüntü alım noktası arasındaki mesafe [m], v = İHA'nın araziye göre hızı [m/sn], t = iki görüntü alım arasında geçen süre [sn] olmak üzere (Şekil 3.13), aşağıdaki denklemler kullanılır:

$$B_b = \text{ileri bindirme oranı (\%)} * AGg \quad (3.4)$$

$$b = AGg - B_b \quad (3.5)$$

$$t = b / v \quad (3.6)$$

Denklemdaki; AG_h = bir görüntünün görüntü çerçevesinin uzunluğu yönünde zeminde kapladığı mesafe [m], ζ_h = görüntü (çerçevenin) uzunluğu [piksel], $Y\ddot{O}A$ = istenen $Y\ddot{O}A$ [cm/piksel] olmak üzere;

$$D = AG_h = (\zeta_h * Y\ddot{O}A) / 100 \quad (3.7)$$

Denklem 3.4, Denklem 3.5 ve Denklem 3.7 birleştirilerek;

$$b = AG_h - \text{bindirme oranı} * AG_h ; b = AG_h * (1 - \text{bindirme oranı})$$

$$b = ((\zeta_h * Y\ddot{O}A) / 100) * (1 - \text{bindirme oranı}) \quad (3.8)$$

Denklem (3.7) ve (3.8) birleştirilince ise Denklem 3.9 olarak hesaplanır (Egels 2001, Linder 2009).

$$t = b / v = ((\zeta_h * Y\ddot{O}A) / 100) * (1 - \text{bindirme oranı}) / v \quad (3.9)$$

3.3.2.3. Fotogrametrik amaçlı İHA kullanımında sonuç kontrolleri

İHA fotogrametrisi, genel kapsamlı olarak hava fotogrametrisine benzer olsa da kendi içerisinde farklılıklar göstermektedir (Fahlstrom ve Gleason 2012, Barba ve ark 2019, Tjahjadi ve ark 2019, Verheyden ve ark 2019). Özellikle yersel fotogrametrik yöntemlere olan yatkınlığı bu tekniği yersel fotogrametri ile hava fotogrametrisi arasında bir noktaya yerleştirmektedir. Çalışmalarda yapılan tüm fotogrametrik amaçlı İHA uçuşlarının arazi işlemlerinde, harita üretim aşamalarında ve kontrol aşamalarında ülkemizde yürürlükte olan BÖHHBÜY yönetmeliği referans alınarak araştırmalar gerçekleştirilmelidir. Bu yönetmelik en son olarak 30 Nisan 2018 tarihinde alınan bakanlar kurulu kararı ile 26 Haziran 2018 tarihli resmi gazetede yayınlanarak yürürlüğe girmiştir. BÖHHBÜY 2018 diğer kendisinden önceki tüm yönetmelikler gibi ülkemizde yapılacak Büyük Ölçekli haritacılık çalışmalarını kapsamaktadır. Yani 1/5000 ölçeği ve daha büyük ölçekli haritalar ile kapsamı sınırlı tutulmaktadır. Örneğin, fotogrametrik amaçlı yapılacak harita ve ortofotolar ölçeğe bağlı olarak belirlenmekte, $Y\ddot{O}A$ 'nın ise 1/500 ve daha büyük ölçekli harita üretimi için 5cm'den, 1/1000 ve daha büyük ölçekli harita üretimi için 10cm'den daha fazla olması kabul edilmemektedir (uçuş koşullarından dolayı $\pm\%10$ değişimler hariç) (Böhhbüy 2018).

İHA ile yapılacak fotogrametrik amaçlı faaliyetlerin hemen hemen tamamı BÖHHBÜY 2018 uyarınca planlanarak gerçekleştirilmelidir. Bu yönetmelik kapsamında da YKN ve denetleme noktaları (fotogrametrik nirengi sırasında dengelemeye doğrudan etki etmeyen ve

sadece dengelemenin doğruluğunu test etmede kullanılan noktalar) araziye tesis edilirken aşağıdaki madde dikkate alınmalıdır (Böhhbüy 2018):

“MADDE 52- (2) Bir blokta, kullanılan YKN sayısının en az %30’u kadar ve bu sayı hiçbir şekilde dört adetten az olmamak kaydıyla denetleme noktaları tesis edilir.”

Ayrıca fotogrametrik nirengi sonuçlarının değerlendirilmesi için aşağıdaki madde göz önünde bulundurulmalıdır;

“MADDE 61- (2) Blok dengeleme sonucunda, denetleme noktalarının karesel ortalama hataları üretilecek harita veya ortofoto ölçeği için gerekli bu Yönetmeliğin 54 üncü maddesinde belirtilen yer örnekleme aralığı cinsinden; X ve Y koordinatlarında $\pm 0.75 \times YÖA$ ’dan (dâhil) ve Z koordinatında $\pm 1 \times YÖA$ ’dan (dâhil) küçük olmalıdır. Denetleme noktalarında maksimum farklar; X ve Y koordinatlarında $\pm 1,5 \times YÖA$ ’dan (dâhil) ve Z koordinatında $\pm 2 \times YÖA$ ’dan (dâhil) küçük olmalıdır.”

GNSS, yersel veya fotogrametrik yöntemlerle ölçülen detayların konum kontrolü de aşağıdaki madde dikkate alınmalıdır:

“MADDE 91 (1) Üretilen haritanın vektör verisinden alınan noktaların koordinatları ile karşılığı detay noktalarının GNSS veya yersel yöntemlerle ölçülen koordinatlarının farklarının Karesel Ortalama Hataları (KOH) aşağıdaki bağıntılarda hesaplanan sınırlar içinde;

a) $KOH_{X,Y} \text{ (cm)} ? \pm (-1,665 \times 10^{-6} \times S^2 + 0,01745 \times S - 1,166),$

b) $KOH_Z \text{ (cm)} ? \pm [1,33 \times KOH_{X,Y} \text{ (cm)}]$ olmalıdır.”

Bu bağıntılarda “S” üretilecek harita ölçeğinin paydasındaki değerdir. Yönetmelikte belirlenen sınırlar içerisinde Çizelge 3.4’de görüldüğü gibi detay noktalarının kontrolü, denetleme noktalarının kontrolü ve denetleme noktaları arasındaki maksimum fark belirlenir (Böhhbüy 2018).

Çizelge 3.4. BÖHHBÜY 2018 yönetmeliğine göre kontrol kriterleri

Detay Noktalarının Kontrolü			
S (Ölçek)	KOH (x,y)	KOH (z)	
500	7.14 cm	9.5 cm	
1000	14.62 cm	19.44 cm	

Denetleme Noktalarının Kontrolü			
S (Ölçek)	YÖA	KOH (x,y)	KOH (z)
500	5 cm	3.75 cm	5 cm
1000	10 cm	7.5 cm	10 cm

Denetleme Noktalarının Maksimum Farkları			
S (Ölçek)	YÖA	KOH (x,y)	KOH (z)
500	5 cm	7.5 cm	10 cm
1000	10 cm	15 cm	20 cm

İHA ile yapılacak fotogrametrik amaçlı faaliyetlerin hemen hemen tamamı BÖHHBÜY 2018 yönetmeliklerine tabi olacak şekilde yapılmalıdır fakat en güncel olarak yayınlanan bu yönetmelik içerisinde kesin ifadelerle İHA için büyük ölçekli harita üretiminde belirli standartlar da bulunmamaktadır. Tapu ve Kadastro Genel Müdürlüğü (TKGM) ulusal olarak büyük ölçekli harita üretimi faaliyetlerinde Türkiye Cumhuriyeti Devleti’nde resmi olarak yetkili iki kurumdan biridir (diğeri de Harita Genel Müdürlüğü – eski bilinen adıyla Harita Genel Komutanlığı’dır). TKGM yayınladığı “İHA ile Kadastral Detay Ölçmeleri, Üretimi ve Kontrol Esasları” başlıklı ekinde durumu daha anlaşılır kılmak ve ihalelerde kurum olarak zarara uğramamak adına bir ek şartname oluşturmuştur. Bu ekin amacı yapılacak işler çerçevesinde özel sektör temsilcilerinin İHA kullanımını tercih etmeleri durumunda gerçekleştirmeleri gereken şartları bildirmektir.

TKGM İHA şartnamesi BÖHHBÜY 2018 aşağıdaki maddeler dikkate alınarak oluşturulmaktadır;

“45.MADDE Detay noktaları, elektronik takeometri, GNSS, LİDAR veya diğer teknik ve yöntemler kullanılarak ölçülebilir.”

“46.MADDE Detay noktalarının izdüşüm koordinatları ve yükseklikleri, elektronik takeometri, GNSS, LİDAR veya diğer teknik ve yöntemler kullanılarak; yatay konum doğruluğu $(dx^2+dy^2)^{1/2} \pm 7$ cm (dâhil)’den daha iyi ve Helmert ortometrik yükseklik doğruluğu $(dh) \pm 7$ cm (dâhil)’den daha iyi olacak şekilde ölçülecektir.”

BÖHHBÜY 2018 hükümleri gereği İHA ile üretilmiş sayısal haritaların (vektör veya ortofoto harita) yukarıda belirtilen konum doğruluklarını sağlamak amacıyla üretim esasları olarak aşağıdaki kriterler belirlenmektedir:

“A. Genel Kriterler

- SHGM tarafından yayınlanan “İnsansız Hava Aracı Sistemleri Talimatı” nda belirtilen kriterlere uyulacaktır.
- Görüntü alımı için kullanılan İHA’nın SHGM’ye ticari olarak kayıtlı olduğuna ilişkin belge ve İHA kullanıcısının pilot sertifikası bulunacaktır.
- SHGM’den alınan ticari uçuş izin belgesi bulunacaktır.
- Görüntü alımında kullanılan kamera için ilgili İdare tarafından onaylanmış “Bu kamera Fotogrametrik Harita Üretiminde Kullanılabilir” yazısı bulunacaktır.

B. Donanım Kriterleri

- Görüntü alımında kullanılan kamera sabit odak uzaklığına sahip olacaktır.
- Görüntü alımında metrik ve metrik kamera haline getirilmiş (self kalibrasyon) kameralar kullanılacaktır.
- Görüntü alım esnasında görüntü yürümesini engelleyecek çözümler bulunacaktır.
- Görüntü alımında kullanılan kamera balıkgözü tipi objektiflere sahip olmayacaktır.
- Hava görüntüsü alımında en az 20 Mega Piksel çözünürlüklü kamera kullanılmalıdır.
- Görüntü alımı yapılacak İHA’larda RTK veya PPK kiti bulunması zorunludur.

C. Üretim Kriterleri


- Proje sahasındaki TUTGA, C1, C2, C3 noktalarının dışında proje sahasına en fazla 400 metre aralıklarla ve idarenin uygun gördüğü sıklıkta yeteri kadar YKN tesis edilecektir.

- YKN noktaları C4 derece nokta hassasiyetinde ölçülecek olup bu noktaların ortometrik kotları ana nivelman ölçüsünde geometrik nivelman ile veya lokal jeoit ile belirlenecektir. YKN'lerin zemin cinsleri boru, çivi veya poligon betonu olacak şekilde tesis edilecek ve uçuş öncesi kanat boyamaları yapılacaktır.
- Uçuş planlaması YÖA 7cm olacak şekilde yapılacak olup, yeryüzü şekillerinden ve hava şartlarından kaynaklanan YÖA sapması %10 geçmeyecektir.
- Bindirme oranları %80 %70 olacak olup sapmalar %10 geçmeyecektir.
- Uçuş planlama raporu sunulacak olup planlamada istenilen değerler (YÖA, Bindirme Oranları, vb.) sunulacaktır.
- Gerçekleşen uçuş raporu hazırlanılacak olup; dönüklük değerleri, görüntü alım koordinatları, planlanan uçuştan sapmalar, görüntülerin YÖA ve bindirme oranları belirtilecektir.
- Uçuş çizelgesi tutulacak olup uçuş bölgesi, görüntü alım krokisi, uçuş başlangıç ve bitiş saati, görüntü alım sayısı belirtilecektir.
- Fotogrametrik nirengi ve fotogrametrik nirengi ölçmeleri işlemleri BÖHHBÜY'nin 59. ve 60. maddesine göre yapılacaktır.”

3.3.2.4. Koordinat dönüşümleri ile alakalı yapılan çalışmalar

GNSS alıcılarıyla gerçekleştirilen CORS (TUSAGA-Aktif) ve RTK çalışmalarında belirlenen koordinatlar TUREF datumunda (Türkiye Ulusal Referans Çerçevesi) -Koordinatları ITRF96 ile 2005,0 referans epoğunda çakışık ve koordinatlarının zamana göre doğrusal değişimi (hızları) ITRF96'nın Sıfır Net-Dönüklüğüne göre tanımlı dört boyutlu ulusal datum-yükseklik değerleri de GRS80 referans elipsoidi üzerinde tanımlanmaktadır. Elipsoidal ölçümlerin ortometrik dönüşümlerinde kullanılan jeoit ondülasyonu ise TG08 (TUDKA99 ile ilişkilendirilmiş, Türkiye Jeoit Modeli) verisine göre düzenlenmelidir. Şekil 3.14'de tanımlanmış elipsoid modeli ile topografya ve jeoit modeli arasındaki ilişki görülmektedir. GNSS alıcısı ile belirlenen yükseklik verisine (Jeoit yüksekliği, h) denklem 3.10'da belirtilen düzeltme gerçekleştirilerek Jeoit ondülasyonu hesaplanır (Makineci ve Karabörk 2016, Inal ve ark 2018, Ayyildiz 2020).

$$N = h - H \quad (3.10)$$



Şekil 3.14. Jeoit ondülasyonu

3.4. Optimizasyon


Eldeki kaynakların belirlenen amaçlar doğrultusunda en verimli olarak kullanılmasının matematiksel olarak formülize edilmesine optimizasyon denilmektedir. En iyileme ya da optimizasyon; bir fonksiyonu minimize ya da maksimize etmek amacı ile gerçek ya da tam sayı değerlerini, tanımlı bir aralıkta seçip, fonksiyona yerleştirerek sistematik olarak bir problemi incelemek ya da çözmek işlemlerini ifade eder (Kubat 2013, Karaboğa 2017). Optimizasyon iki aşamalı bir tekniktir. Birinci aşama modelleme ve ikinci aşama da analiz etmektir (Tan ve Bora 2017). Optimizasyon; bir gerçel fonksiyonu en küçük değere ya da en büyük değere yakınsamak amacıyla, gerçek ya da tam sayı değerlerini, belirli bir aralıkta, fonksiyona uygulayarak sistematik olarak bir problemi analiz etmek ya da sonuç bulmak işlemlerini ifade eder. Bir $f(x)$ fonksiyonunu ele alırsak, x' noktasındaki x_n 'e göre kısmi türev $\partial f(x)/\partial x_n$ olur. Tüm kısmi türevler bir sütun vektörü olarak düzenlenirse bu vektöre «Gradyan» –Gradient-vektör denir ve ∇f ile (grad f) gösterilir. Geometrik olarak gradyan vektörü x_n anında teğet olan $f(x)$ =sabit düzlemine diktir. Gradyan vektörü fonksiyonun en hızlı artış (azalış) gösterdiği yönü belirlemektedir (Kubat 2013, Karaboğa 2017).

İHA çalışmalarında, optimizasyonun gerekliliği aşikârdır (Zhang ve ark 2010, Tan ve Bora 2017, Radmanesh ve ark 2018, Dewangan ve ark 2019, Manconi ve ark 2019, Wai ve Prasetya 2019). Optimizasyon aşamalarını sağlayacak şekilde problemi ortaya koymak, verilerden model oluşturmak ve modeli çözümlmek için İHA çalışmalarına uyabilecek bir algoritma belirlenmesi gerekir (Zhang ve ark 2016, Azabi ve ark 2019, Duong ve ark 2019).

Tercih edilecek optimizasyon algoritmalarının ve matematiksel modellerin, kullanıcılara ve araştırmacılara teknik olarak önemli bir destek sunması gereklidir. Bir algoritma veya yöntem seçerken en temel varsayım, kusursuz algoritmanın olmadığı kabul edilmesidir. Optimum algoritmayı bulmak için bazen deneme yanılma yöntemine, bazen de literatür bilgisine başvurulur. Ek olarak, algoritma seçimi, üzerinde çalıştığınız verinin boyutuna ve türüne, verilerden elde etmek istediğiniz bilgilere ve nasıl kullanılacağına da bağlıdır (Perez-Carabaza ve ark 2018, Chiang ve ark 2019).

3.4.1. Yapay sinir ağları

Yapay Sinir Ağlar (YSA) tecrübe ile elde etmiş olduğu bilgileri fiziksel hücrelerine kaydeden ve gerektiği takdirde bu bilgileri kullanabilen hücre yapılarıdır. İnsan beyninin fonksiyonlarından esinlenmiş olan yapay sinir ağları öğrenme kabiliyeti sayesinde herhangi bir destek almadan yeni bilgiler üretme, oluşturma ve keşfedebilme özelliklerine sahiptir. Bu özellikleri sayesinde YSA sınıflandırma, optimizasyon ve örüntü tanıma problemleri gibi birçok sorunun çözülmesinde sıklıkla kullanılır (Goudos ve ark 2019, Takeuchi ve Nakanishi 2019, Wai ve Prasetya 2019, Herrero-Huerta ve ark 2020). YSA birden fazla sinir hücresinin bir araya gelmesi ile oluşmaktadır. Bu sebeple tüm ağın anlaşılması için bir sinir hücresinin özelliklerinin anlaşılması gerekir. YSA; girdiler, ağırlıklar, aktivasyon fonksiyonu, toplama fonksiyonu ve çıktılar adı altında beş ana ögesi bulunmaktadır. Sinir hücrelerin oluşturduğu ağ ise giriş, gizli ve çıkış katmanları olmak üzere üç katmandan oluşur (Şekil 3.15). YSA, istatistiksel yöntemlere kıyasla kullanımı ve anlaşılması kolay olan ve doğrusal olmayan bir modeldir. YSA parametrik olmayan bir model iken, istatistiksel yöntemlerin çoğu daha yüksek bir istatistik arka planına ihtiyaç duyan parametrik modellerdir. Geri yayılım öğrenme metodu içeren YSA, çeşitli sınıflandırma ve tahmin problemlerinin çözümünde yaygın olarak kullanılmaktadır. Geri yayılım hızı, gradyan vektörünü yakınsamada yavaş olsa bile, yüksek doğruluk sunarak önemli bir avantaj sağlamaktadır (Sağıroğlu ve ark 2003, Yılmaz 2017).




Şekil 3.15. YSA katman yapısı

3.4.2. Yapay sinir ağları ile optimizasyon ve algoritma yapıları

YSA, fiziksel hücreler konusunda deneyimle edindiği bilgileri kaydeden ve gerektiğinde bu bilgileri kullanabilen bir algoritmadır. İnsan beyninin işlevlerinden ilham alan YSA, herhangi bir destek olmadan öğrenebilir, yeni bilgiler üretebilir ve keşfedebilir. Bu özelliklerinden dolayı YSA, sınıflandırma, optimizasyon ve örüntü tanıma problemleri gibi birçok problemi çözmek için sıklıkla kullanılmaktadır. Birden fazla sinir hücresinin kombinasyonu YSA'yı oluşturur. Bu nedenle, tüm ağı anlamak için bir sinir hücresinin özelliklerini anlamak gerekir. Girişler, ağırlıklar, aktivasyon fonksiyonu, toplama fonksiyonu ve çıkışlar altında beş ana unsur vardır. Sinir hücreleri ağı üç katmandan oluşur: giriş katmanı, gizli katman ve çıktı katmanı (Şekil 3.15) (Kubat 2013, Karaboğa 2017, Alpaydin 2020).


- I. Girdiler; sinir sisteminde nöronlara gelen uyarının karşılığıdır. Yapay sistemde girdi sisteme tanımlanan veridir. Ağırlık eğitiminde kullanılan, öğrenmesi istenilen verilerdir. Girdiler ile toplanan veriler bir araya getirilmek üzere nöron çekirdeğine biriktirilir.
- II. Ağırlıklar; Yapay sinir hücresine gelen bilgiler, çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlıklarıyla çarpılırlar. Böylece girdilerin üretilmesi istenen çıktı üzerinde etkisi ayarlanabilmektedir.
- III. Toplama fonksiyonu; bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdileri toplayarak hücrenin net girdisini hesaplayan fonksiyondur (Karaboğa 2017). Birleştirme fonksiyonu da (NET) denir. YSA’da bilinen toplam altı farklı toplama fonksiyonu vardır (Şekil 3.16).



Şekil 3.16. YSA Toplama Fonksiyonları

- IV. Aktivasyon fonksiyonu; toplama fonksiyonundan çıkan NET toplam hücrenin çıktısını oluşturmak üzere aktivasyon fonksiyonuna iletilir. Geri beslemeli ağlarda aktivasyon

fonksiyonunun türevi de hesaplamaya dâhil edildiği için aktivasyon fonksiyonu seçilirken en önemli unsur türevinin kolay hesaplanabilir olmasıdır (Karaboğa 2017). YSA’da en sık kullanılan altı farklı aktivasyon fonksiyonu vardır (Şekil 3.17).



Şekil 3.17. YSA Aktivasyon Fonksiyonları

V.Çıktılar; aktivasyon fonksiyonundan çıkan değer nöronunun sonuç değeri olarak tanımlanmaktadır. Çıktı değeri modelin seçimine göre ister sonuç çıktı olur, ister geri besleme için ağıın içerisine tekrar katılır.

Bir $f(x)$ fonksiyonunu ele alırsak, x' noktasındaki x_n 'e göre kısmi türev $\partial f(x) / \partial x_n$ olur. Tüm kısmi türevler bir sütun vektörü olarak düzenlenirse bu vektöre «Gradyan» vektörü denir ve ∇_f ile (grad f) gösterilir.

Geometrik olarak gradyan vektörü x_n anında teğet olduğu $f(x)$ =sabit düzlemine dik olmalıdır. Gradyan vektörü fonksiyonun en hızlı artış (veya azalış) gösterdiği yönü belirlemektedir (Sağıroğlu ve ark 2003, Yılmaz 2017, Alpaydin 2020).

3.4.3. YSA eğitim algoritmaları

YSA, genellikle herhangi bir matematiksel fonksiyon tarafından tanımlanamayan karmaşık problemlerin, çok yüksek doğrulukla modellemesini sağlar. Örneğin, x adet girdisi, y adet çıktısı olan bir sistemde girdi/çıktı değerleri süreklilik arz edecek şekilde kaydedilir ve tüm girdi/çıktıların regresyon analizi yapılır ve aralarındaki matematiksel ilişkinin belirlenebilmesi için bir amaç fonksiyonu tanımlaması yapılır. Sonuçta, çözülmesi çok karmaşık bir fonksiyon yapısı ortaya çıktığından çözümü doğrudan hesaplama yöntemleriyle yıllarca sürebilir. Oysa YSA ile bu karmaşık problemi, x adet girdi nöronu ve y adet çıktı nöronu tanımlayarak çok kısa sürede ve yüksek doğrulukla modellemek mümkündür (Altun ve ark 2019, Goudos ve ark 2019, Takeuchi ve Nakanishi 2019, Wai ve Prasetya 2019).

YSA optimizasyon modelinin eğitimi kullanımı için literatürde bilinen en temel iki algoritma; Gradyan Descent algoritması (GD) ve Levenberg-Marquardt (LM) algoritmasıdır. GD Algoritması şu şekilde açıklanabilir; $Y = (x)$ değişkene bağlı doğrusal bir fonksiyondur θ bu fonksiyondaki girişlerin ağırlık değeridir (Khan ve ark 2018, Schulze-Horn ve ark 2020). Tüm fonksiyonların toplamı Denklem 3.11 ve Denklem 3.12'deki gibidir.

$$W_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 \quad (3.11)$$

$$W(x) = \sum_{i=0}^n \theta_i x_i = \theta^T x \quad (3.12)$$

Ağırlık vektörünün ve x vektörünün (seçilen giriş parametresi) transpoze edilmesi gerekmektedir. Ağırlık vektörünün ve x vektörünün, seçilen bir veri setinde ne olduğunu bilmek için bir maliyet fonksiyonu tanımlanır (Denklem 3.13).

$$J_{\theta} = \frac{1}{2} \sum_{i=1}^m (W(x^{(i)}) - y^{(i)})^2 \quad (3.13)$$

Amaç, θ değerini atayarak fonksiyonu en uygun hale getirmektir (Denklem 3.14'te gösterilen minimum veya maksimum).

$$\theta_j := \theta_j - \alpha \frac{\partial}{\partial \theta_j} J_{\theta} \quad (3.14)$$

(: =) ; Tanımı yukarıdaki Denklem 3.15, 3.16 ve 3.17'de verildiği gibidir. Bu şekilde kısmi türevlerle kendini yeniler. Kısmi türev, bir maliyet fonksiyonu olarak alınır.

$$\frac{\partial}{\partial \theta_j} J_{\theta} = \frac{\partial}{\partial \theta_j} (W_{\theta}(x) - y)^2 \quad (3.15)$$

$$\frac{(W_{\theta}(x) - y) * \partial}{\partial \theta_j} (\sum_{i=0}^n \theta_i x_i - y) \quad (3.16)$$

$$(W_{\theta}(x) - y)x_j \quad (3.17)$$

$$\theta_j := \theta_j - \alpha \frac{\partial}{\partial \theta_j} J_{\theta} \rightarrow \theta_j := \theta_j + \alpha (y^{(i)} - W(x^{(i)})) x_j^{(i)} \quad (3.18)$$

Algoritmaya (θ_j) değerini uyarlamak için bir “for” döngüsü içinde birleşene kadar tekrar edilir. [$\{\theta_j := \theta_j + \alpha \sum_{i=1}^m (y^{(i)} - W(x^{(i)})) x_j^{(i)}\}$ tüm j değerleri için”]

Bu algoritma için, öğrenme oranı α ne kadar küçükse, maliyet fonksiyonu (θ) o kadar azdır ve yakınsama olasılığı o kadar yüksektir. α büyük kalırsa θ asla yakınsak olmayabilir. Bu durumda algoritmanın başarısız olduğunu söylenir (Khan ve ark 2018, Mercier ve ark 2018).

GD algoritması; ağırlığı, girdi parametreleri, transfer fonksiyonları ve türev fonksiyonları olan herhangi bir ağı eğitebilir. Geri yayılım (Backpropagation), ağırlık ve sapma değişkenleri girdilere göre performans türevlerini hesaplamak için kullanılır.

LM algoritması; Hessian matrisini hesaplamak zorunda kalmadan ikinci dereceden eğitim hızına yaklaşmak için tasarlanır. Performans fonksiyonu «kareler toplamı» türünde ise (ileri beslemeli ağ eğitiminde genelde olduğu gibi), o zaman Hessian matrisi şu şekilde tahmin edilebilir (Denklem 3.19):

$$H = J^T J \quad (3.19)$$

Sonrasında da gradyan şu şekilde (Denklem 3.20) hesaplanabilir:

$$g = J^T e \quad (3.20)$$

Burada J , ağırlıklara ve biaslara göre ağ hatalarının ilk türevlerini içeren Jacobian matrisidir ve «e» ağ hatalarının bir vektörüdür. Jacobian matrisi, Hessian matrisini hesaplamaktan çok daha az karmaşık olan standart bir geri yayılım tekniği ile hesaplanabilir.

LM Algoritması nispeten hızlıdır ve yalnızca birinci dereceden kısmi türevlerle çalışır (Okkan ve ark 2018). Şu şekilde açıklanabilir (Denklem 3.21 ve Denklem 3.22);

$$\eta \omega(i) = -[J_i^T * J_i + \mu_i * I]^{-1} * J_i^T * e_i \quad (3.21)$$

$$\omega(i+1) = \omega(i) + \eta \omega(i) \quad (3.22)$$

Denklemlerde ω ağırlık, I birim matris, $\eta_{\omega}(i)$ i noktasındaki ağ ağırlıklarıdır. Burada J , Jacobian matrisidir ve ağ hatalarının ağırlıkça ilk türevlerini içerir. μ , Marquard parametresini (eğitim katsayısını) belirtir ve μ , her yeni yinelemede LM algoritması için güncellenen bir

bileşendir. Herhangi bir yineleme adımında çıktı ve hedef değerler arasındaki farkın karelerinin toplamı azalırsa, μ bir sonraki yineleme için sabit bir bozulma oranıyla çarpılarak kullanılır. Bozulma oranı genellikle 0.1 olarak alınır. Diğer alternatif durumda, μ bir sonraki yineleme için seçilen distorsiyon oranına bölünerek kullanılır. Böylece, ağın performansı her adımda iyileştirilir (Levenberg 1944, Marquardt ve Mathematics 1963, Okkan ve ark 2018).

3.4.4. Normalizasyon işlemi


Normalleştirme işlemi ham veriye uygulanır ve uygulandığı parametreler onu eğitime uygun hale getirir. YSA eğitimi, ham veri seti normalleştirilmeden uzatılabilir. Normalleştirme işlemlerinde farklı teknikler kullanılabilir. Literatürde birçok veri normalleştirme türü vardır. Bunlardan bazıları Z-Skoru Normalizasyon, Minimum-Maksimum Normalizasyon, Medyan Normalizasyon, Sigmoid Normalizasyon ve D_Min_Max Normalizasyondur. Tüm normalizasyon yöntemlerinin farklı amaçları olmasına rağmen literatürde YSA'da en başarılı D_Min_Max Normalizasyonu olarak belirlenmiştir (Yavuz ve Deveci 2012). D_Min_Max Normalizasyon bir işlev olarak; 0,1 ile 0,9 arasındaki tüm verileri normalize etmek üzerine kuruludur. Girdi kümesindeki en küçük sayı ($X_{\min}$), girdi kümesindeki (Denklem 3.23) en büyük sayı ($X_{\max}$) ve girdi değerleri (X_n) dahil olmak üzere bu denklemde normalize edilen tüm veriler tek boyutlu hale gelir (Doğan ve ark 2007, Ioffe ve Szegedy 2015).

$$x' = \left[0,8 * \left(\frac{x_n - x_{\min}}{x_{\max} - x_{\min}} \right) \right] + 0,1 \quad (3.23)$$

Normalleştirilmiş veri x' belirlendikten sonra, 0-1 aralığındaki tüm girişlerin ölçeklendirilmesi, hem farklı ortamlardan gelen bilgilerin aynı ölçekte tanımlanmasına neden olur hem de yanlış girilen çok büyük ve küçük değerlerin etkisini en aza indirir (Ioffe ve Szegedy 2015).


3.5. Grafik tabanlı arayüz

GUIDE (Graphical User Interface Development Environment) grafiksel kullanıcı arayüzü geliştirme çerçevesi olarak bilinmektedir. GUIDE başlığıyla kullanıcılara sunulan bu eklenti kodlama dilinde yapılan işlemlerin görsel olarak (grafik tabanlı) sonuçlar verebilmesi amacıyla tercih edilmektedir. Burada yapılan işlemler temel programlama dilini kullanarak seçimler yapmak, sonuçlar üretmek ve görsel olarak anlaşılabilir bir sonuç almak için önemlidir. Temel olarak kullanımı öncelikle Şekil 3.18'de görülen boş bir sayfa açarak başlamaktadır.



Şekil 3.18. Genel başlangıç görüntüsü

Boş bir sayfa seçerek açılışı gerçekleştirdikten sonra amaca uygun butonları seçerek eklenebileceği ana ekran çıkmaktadır. Program sonucunda ne üretmek isteniyorsa o çerçeveden uzaklaşmadan ihtiyaç kadar buton eklemek önemlidir. Sonuçta oluşacak GUI’de hiç çalışmayan bir buton olması veya yanlış çalışan bir buton olması kesinlikle kullanıcılarda olumsuz sonuç ortaya çıkaracaktır. Şekil 3.19’da görülen buton tiplerinin her biri farklı bir amaca uygun olarak tercih edilebilmektedir.



Şekil 3.19. Butonların seçildiği ekran

Belirlenen tuşlara eklenen özellikler ile birlikte GUI yavaş yavaş mantıklı sonuçlar vermeye başlayacaktır. Yapılmak istenen işlem ne kadar karışık olursa olsun burada adım adım gidilmesi ve bir aşama tamamlanmadan yeni aşamaya geçilmemesi önerilir. Her bir tuşa bir matematiksel işlem atadıktan sonra GUI tamamlanarak kullanılabilir hale gelmiş olacaktır.

Buraya kadar çalışmada kullanılan materyallerin ve yöntemlerin tanımlandığı bu bölümde genel olarak çalışma alanları ve kullanılan İHA'lar açıklanmıştır. Ayrıca YSA yönteminin, fotogrametrik temellerin, fonksiyonların ve algoritmaların matematiksel temellerinin açıklandığı bu bölümden sonra ise sırasıyla yapılan deneylerin, gözlemlerin, uygulamaların ve bulguların gösterildiği bir bölümle devam etmektedir.



4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Optimizasyon çalışmasında kullanılmak üzere ihtiyaç duyulan veriler hazır veriler olmadığı için, veri setlerinin baştan sona kadar çalışma süresince gerçekleştirilmesi gerekliydi. Veri setlerini elde edebilmek için iki farklı alternatif vardı. Birinci alternatif arazi koşullarında belirlenen test bölgelerinde gerçek arazi şartlarında veri seti üretmek ve ikincisi de bilgisayar sistemlerinde simülasyon yazılımlarında sanal ortamda veri setini üretmektir. Birinci alternatif seçilerek gerçekleştirilen bu çalışmada yapılan deney ve gözlemler, elde edilen tüm veri setleri tamamen gerçek koşullarda üretilmiştir. Yapılan tüm çalışmalar süresince gerçekleştirilen araştırmaların ve birbiriyle alakalı sonuçların bir araya getirilmesi ve değerlendirilmesi için belirli aşamalar tasarlanmıştır. Arazi çalışmaları, bilgisayar kodlama ve optimizasyon araştırmaları arasındaki ilişkiyi kurabilmek ve dengede tutabilmek, araştırmada karşılaşılan bir zorluktu. Ayrıca, sadece arazi çalışmalarına ve yersel ölçümlere dayalı yapılan bir araştırmada optimizasyon modeli elde edebilmek neredeyse imkansız olacağı için, bilgisayar tekniklerinden ve yapay zeka uygulamalarından yararlanılarak çalışma belirli bir temele oturtulmuştur. Çalışmanın gelecekte ve günümüzde anlamlı olabilmesi ve araştırmacılara yardımcı olabilmesi için bu verilerin sağlam ve uyumlu olmasına özen gösterilmiştir. Ayrıca veriler üzerinden elde edilen optimizasyon modelinin de tutarlı olması ve yüksek doğrulukta sonuçlar verebilmesine de dikkatle yaklaşılmıştır.

4.1. Arazi Çalışmaları Bulguları

Bu araştırmada yapılan çalışmalar sırasında optimizasyona uygun olarak yapılan ve başlangıç bitiş durumu kayıt altına alınarak, sonuç doğrulukları araştırılan toplam elli üç farklı uçuş gerçekleştirilmiştir. Gerçekleştirilen uçuşların Test Bölgesi A, Test Bölgesi B ve Test Bölgesi C’de gerçekleştirilen kısımları Konya İli, Karapınar İlçesinde yapılmıştır. Çizelge 4.1, Çizelge 4.2, Çizelge 4.3 ve Çizelge 4.4’te gösterilen değerler, yapılan uçuşlardan elde edilen sonuçlardır. Test Bölgesi D (Kampüs Alanı) içerisinde gerçekleştirilen toplam yirmi bir uçuş Çizelge 4.5 ve Çizelge 4.6’da tanımlanmıştır. Ayrıca geri kalan on altı İHA uçuşu da Çizelge 4.7’de gösterildiği gibidir. Çizelge 4.7’de verilen tüm uçuşlar da Konya İli, Selçuklu İlçesi’nde belirlenen Test Alanı E (vadi alanı) sınırlarında gerçekleştirilmiştir.

Çizelge 4.1. Test alanı (A-B) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
6.08.2018	515 x 560	70	63	80	568	6254	20:53
6.08.2018	515 x 560	70	63	90	268	6900	16:12
6.08.2018	515 x 560	70	63	100	337	5142	13:10
6.08.2018	515 x 560	80	72	100	604	6263	22:39
7.08.2018	515 x 560	70	63	120	182	4229	11:04
7.08.2018	515 x 560	80	72	120	416	5151	16:09

Çizelge 4.2. Test alanı (A-B) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
7.08.2018	510 x 560	80	65	120	176	15200	18:00
8.08.2018	510 x 560	80	65	170	134	16500	18:00

Çizelge 4.3. Test alanı (A-B) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
6.08.2018	591 x 958	70	63	100	404	8148	18:18
6.08.2018	806 x 816	70	63	100	467	7192	17:33
7.08.2018	688 x 647	70	63	100	325	5393	12:37

Çizelge 4.4. Test alanı (C) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
8.08.2018	276 x 343	70	63	70	198	2932	07:46
8.08.2018	317 x 382	70	63	70	236	3245	09:34
8.08.2018	556 x 569	70	63	90	417	5613	14:51

Çizelge 4.5. Kampüs alanı (Test Alanı D) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
29.06.2018	533 x 66	80	72	100	105	1859	05:12
29.06.2018	371 x 250	80	72	100	155	1862	06:42
29.06.2018	197 x 327	80	72	90	105	1340	04:41
29.06.2018	281 x 160	80	72	90	156	1717	06:14
29.06.2018	369 x 151	80	72	70	262	2103	09:01
29.06.2018	513 x 66	80	72	50	439	2427	14:02
2.07.2018	284 x 265	80	72	90	120	1862	07:14
2.07.2018	284 x 265	80	72	80	144	2060	08:36
2.07.2018	187 x 323	80	72	50	263	2053	09:57

Çizelge 4.6. Kampüs alanı (Test Alanı D) içinde yapılan uçuşlar

Gün	Alan m ² (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
8.10.2018	556 x 569	70	63	90	417	5613	14:51
10.10.2018	187 x 103	80	72	80	182	1802	07:05
10.10.2018	188 x 86	80	72	72	125	1855	07:41
19.10.2018	1099 x 440	70	60	120	219	8414	15:20
19.10.2018	150 x 432	70	70	120	52	1831	08:46
22.10.2018	1157 x 428	70	65	120	224	9510	13:45
22.10.2018	108 x 421	70	65	120	39	1333	06:58
23.10.2018	1120 x 422	70	65	120	243	8939	27:18
26.10.2018	430 x 1100	70	65	120	256	9142	18:28
30.10.2018	168 x 838	70	70	120	100	3473	12:05

Çizelge 4.7. Karma alan (Test Alanı E) içinde yapılan uçuşlar

Gün	Alan (m x m)	İleri Bindirme Oranı (%)	Yan Bindirme Oranı (%)	Yükseklik (m)	Görüntü Sayısı (Adet)	Çevre (m)	Uçuş Süresi (dk.)
3.7.2019	1500 x 2000	70	60	160	176	6894	16,24
3.7.2019	1500 x 2000	70	60	130	380	9401	24,06
3.7.2019	1500 x 2000	70	60	110	71	5098	12,30
3.7.2019	1500 x 2000	70	60	90	120	6106	14,00
3.7.2019	1500 x 2000	70	60	85	417	9965	29,36
3.7.2019	1500 x 2000	70	60	75	178	7253	17,48
4.7.2019	1000 x 2000	60	40	160	214	8029	19,48
4.7.2019	1000 x 2000	60	40	130	383	9608	26,42
4.7.2019	1000 x 2000	60	40	110	84	5876	12,00
4.7.2019	1000 x 2000	60	40	90	258	5923	13,36
4.7.2019	1000 x 2000	60	40	75	325	6841	16,06
6.7.2019	600 x 500	80	65	160	430	10985	31,18
6.7.2019	600 x 500	80	65	125	313	8236	20,12
6.7.2019	600 x 500	80	65	90	387	9901	24,30
6.7.2019	600 x 500	80	65	85	472	12056	33,54
6.7.2019	600 x 500	80	65	75	363	9008	22,24

Çizelge 4.8. Çalışma süresince üretilen (optimizasyonda kullanılan) tüm verileri gösteren çizelge

Uçuş Numarası	Uçuş Tarihi	İHA Tipi	Arazi Eğimi (Ortalama, °, %)	Arazi Tipi	Arazinin Toplam Alanı (m x m)	YÖA (cm/piksel)	Alınan Görüntü Sayısı	Bindirme Oranları (İleri/Yan,%)	Atmosferik Koşullar (Rüzgâr, km/h)	Uçuş Süresi (dk.)	Pil Durumu Uçuş Öncesi (%)	Pil Durumu Uçuş Sonrası (%)
A1	3.7.2019	Sabit Kanatlı	10 - 15	Kırsal	1500 x 2000	3,8	176	70 / 60	8	16,24	100	58
A2	3.7.2019	Sabit Kanatlı	10 - 15	Kırsal	1500 x 2000	3	380	70 / 60	9	24,06	100	55
A3	3.7.2019	Sabit Kanatlı	10 - 15	Kırsal	1500 x 2000	2,5	417	70 / 60	6	29,36	100	45
B1	3.7.2019	Döner Kanatlı	10 - 15	Kırsal	1500 x 2000	3	71	70 / 60	8	12,30	100	47
B2	3.7.2019	Döner Kanatlı	10 - 15	Kırsal	1500 x 2000	2,5	120	70 / 60	5	14,00	100	40
B3	3.7.2019	Döner Kanatlı	10 - 15	Kırsal	1500 x 2000	2	178	70 / 60	4	17,48	100	27
C1	4.7.2019	Sabit Kanatlı	15 - 25	Kırsal	1000 x 2000	3,8	214	60 / 40	11	19,48	100	62
C2	4.7.2019	Sabit Kanatlı	15 - 25	Kırsal	1000 x 2000	3	383	60 / 40	12	26,42	100	50
D1	4.7.2019	Döner Kanatlı	15 - 25	Kırsal	1000 x 2000	3	84	60 / 40	14	12,00	100	50
D2	4.7.2019	Döner Kanatlı	15 - 25	Kırsal	1000 x 2000	2,5	258	60 / 40	11	13,36	100	42
D3	4.7.2019	Döner Kanatlı	15 - 25	Kırsal	1000 x 2000	2	325	60 / 40	10	16,06	100	35
E1	6.7.2019	Sabit Kanatlı	< 10	Tarımsal	600 x 500	3,8	430	80 / 65	16	31,18	100	42
E2	6.7.2019	Sabit Kanatlı	< 10	Tarımsal	600 x 500	2,5	472	80 / 65	15	33,54	100	36
F1	6.7.2019	Döner Kanatlı	< 10	Tarımsal	600 x 500	3,5	313	80 / 65	22	20,12	100	30
F2	6.7.2019	Döner Kanatlı	< 10	Tarımsal	600 x 500	2,5	363	80 / 65	22	22,24	100	26
F3	6.7.2019	Döner Kanatlı	< 10	Tarımsal	600 x 500	2	387	80 / 65	20	24,30	100	20
G1	29.6.2018	Döner Kanatlı	20 - 30	Kırsal	281 x 160	2,45	156	80 / 72	15	6.14	100	69
G2	29.6.2018	Döner Kanatlı	20 - 30	Kırsal	369 x 151	1,9	262	80 / 72	10	9.55	100	58
G3	29.6.2018	Döner Kanatlı	< 10	Kentsel	513 x 66	1,35	439	80 / 72	9	14.02	100	49
G4	29.6.2018	Döner Kanatlı	< 10	Kentsel	533 x 66	2,75	105	80 / 72	16	5.12	100	73
G5	29.6.2018	Döner Kanatlı	20 - 40	Orman	371 x 250	2,75	155	80 / 72	18	6.42	100	67
G6	29.6.2018	Döner Kanatlı	20- 40	Orman	356 x 287	2,2	228	80 / 72	14	9.01	100	62
G7	29.6.2018	Döner Kanatlı	< 10	Orman	197 x 327	2,45	105	80 / 72	19	4.41	100	77
G8	29.6.2018	Döner Kanatlı	< 10	Orman	187 x 323	1,35	263	80 / 72	12	9.57	100	57


Çizelge 4.8. Çalışma süresince üretilen tüm verileri gösteren çizelge'nin devamı

G9	29.6.2018	Döner Kanatlı	< 10	Kentsel	284 x 265	2,2	144	80 / 72	8	8.36	100	65
G10	29.6.2018	Döner Kanatlı	< 10	Kentsel	284 x 265	2,45	120	80 / 72	11	7.14	100	70
H1	6.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	2,75	337	70 / 63	27	13.1	100	45
H2	6.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	2,75	604	80 / 72	28	22.39	100	25
J1	6.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	2,2	568	70 / 63	23	20.53	100	29
J2	6.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	2,45	268	70 / 63	25	16.12	100	35
K1	6.8.2018	Döner Kanatlı	< 10	Tarımsal	591 x 958	2,75	404	70 / 63	6	18.18	100	27
K2	6.8.2018	Döner Kanatlı	< 10	Tarımsal	806 x 816	2,75	467	70 / 63	6	17.33	100	34
L1	7.8.2018	Sabit Kanatlı	0 - 45	Kırsal	510 x 560	2,3	176	80 / 65	28	18,00	100	62
L2	7.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	3,3	182	70 / 63	32	11.04	100	52
M1	7.8.2018	Döner Kanatlı	0 - 45	Kırsal	515 x 560	3,3	416	80 / 72	35	16.09	100	35
M2	7.8.2018	Döner Kanatlı	< 10	Tarımsal	688 x 647	2,75	325	70 / 63	6	12.37	100	49
N1	7.8.2018	Döner Kanatlı	5 - 20	Kırsal	503 x 955	3	126	70 / 65	22	13.03	100	50
O1	7.8.2018	Döner Kanatlı	5 - 20	Kırsal	1208 x 1054	3	191	70 / 65	20	17.57	100	27
O2	8.8.2018	Sabit Kanatlı	0 - 45	Kırsal	510 x 560	3,25	134	80 / 65	34	21,00	100	59
O3	8.8.2018	Döner Kanatlı	< 10	Kırsal	276 x 343	1,9	198	70 / 63	5	7.46	100	66
P1	8.8.2018	Döner Kanatlı	< 10	Kırsal	317 x 382	1,9	236	70 / 63	5	9.34	100	56
P2	8.8.2018	Döner Kanatlı	< 10	Kırsal	556 x 569	2,45	417	70 / 63	4	14.51	100	46
R1	8.8.2018	Döner Kanatlı	5 - 20	Kırsal	841 x 981	3	146	70 / 65	18	13.45	100	48
R2	8.8.2018	Döner Kanatlı	5 - 20	Kırsal	413 x 932	3	136	70 / 65	19	11.3	100	51
S1	10.10.2018	Döner Kanatlı	< 10	Kentsel	188 x 86	1,95	125	80 / 72	9	7.41	100	68
S2	10.10.2018	Döner Kanatlı	< 10	Kentsel	187 x 103	2,2	182	80 / 72	14	7.05	100	70
T1	19.10.2018	Döner Kanatlı	< 10	Kentsel	1099 x 440	3,3	219	70 / 65	18	15.2	100	39
T2	19.10.2018	Döner Kanatlı	< 10	Kentsel	150 x 432	3,3	52	70 / 65	16	8.46	100	62
U1	22.10.2018	Döner Kanatlı	< 10	Kentsel	1157 x 428	3,3	224	70 / 65	17	13.45	100	46
U2	22.10.2018	Döner Kanatlı	< 10	Kentsel	108 x 421	3,3	39	70 / 65	17	6.58	100	64
V1	23.10.2018	Döner Kanatlı	< 10	Kentsel	1120 x 422	3,3	243	70 / 65	19	13,18	100	54
Y1	26.10.2018	Döner Kanatlı	< 10	Kentsel	430 x 1100	3,3	256	70 / 65	16	18.28	100	47
Z1	30.10.2018	Döner Kanatlı	< 10	Kentsel	168 x 838	3,3	100	70 / 65	17	12.05	100	59

Çalışmada belirlenen problemin, amacın ve hedeflerin gerçekleştirilmesiyle oluşturulan deney ve gözlemlere dayalı Çizelge 4.8'in "Uçuş Numarası" sütunu yapılan her bir deneyin diğerlerinden ayırmak için belirleyici bir numara olarak atanmıştır. Gözlemin yapıldığı tarih bir sonraki sütunda, ardından sırasıyla kullanılan İHA tipi, arazinin topografik eğim yapısı, test alanının belirleyici özellikleri, uçuş yapılan yükseklikte İHA'nın sunduğu YÖA, toplam alınan görüntü sayısı, ileri ve yan bindirme oranları, rüzgâr parametresi, toplam kalkış ve iniş arasında geçen uçuş süresi ve bataryanın uçuş süresince yaptığı değişim olarak çizelgede gösterilmiştir.

4.2. İHA Uçuşlarından Üretilen Sonuç Ürünler

Farklı çalışma bölgelerinden elde edilen tüm veriler işlenerek her uçuşa ait sayısal sonuç ürünler elde edilmiştir. 3B model oluşturmak için, alt aşamaları tüm uçuşlar için aynı koşullar altında gerçekleştirilmelidir (Remondino ve ark 2011, Barba ve ark 2019). Üretim aşamalarının aynı seçilmesinin sebebi, üretilen ürünlerin doğruluğunda kullanılan yazılımların etkisinin sabit kabul edilebilmesi olarak söylenebilir. Sonuç ürünler üretilirken, henüz en uygun şartların belirlenmemiş olmasından dolayı yazılımların sunduğu başlangıç değerleri (görüntü birleştirmek için tespit edilecek nokta sayısı, birleştirmek için kullanılacak nokta sayısı, 3B model üretim kalitesi vs.) varsayılan değerler kullanılmıştır. Sonuçta elde edilen görüntüler kullanılarak, sonuç ürünler (SAM, 3B Model, Ortomozaik ve Eşyükselti Eğrileri) oluşturulmuştur (Şekil 4.1).




Şekil 4.1. Sabit kanatlı İHA ile Test Alanı A'dan elde edilen örnek SAM, ortomozaik üretimi ve eşyüksekti eğrileri I

Haritalar görsel olarak anlaşılabilir şekilde birleştirilmiştir. Eş yükselti eğrileriyle ortomozaikler kartografik olarak birlikte sunulmuştur ve görsel olarak anlamlı görünmesi sağlanmıştır. Aynı uçuş parametrelerine sahip Ortomozaik-SAM görüntüleri de daha sonraki işlem adımlarında karşılaştırma yapabilmek için stereo çift oluşturacak şekilde birleştirilmiştir.


Geometrik ve radyometrik doğruluk bakımından en iyi ortomozaik üretilmesi için; seçilen uçuş yönü, GNSS alıcısının doğruluğu, kamera çözünürlüğü, kullanılan görüntü eşleme algoritması ve uçuş esnasındaki rüzgâr yönü/şiddeti parametrelerine dikkat edilmelidir (Öztürk ve ark 2017, Tsai ve Lin 2017, Hung ve ark 2019). Bu nedenle

çalışma kapsamında planlanan optimizasyon modeli açısından daha yüksek doğrulukta sonuçlar verebilecek İHA uçuş planlamaları yapılmıştır.

Görseller birleştirilirken, modeller içinde tutarlılık gösteren, girdi parametrelerine göre karşılaştırılması uygun olanlar seçilmiştir. Örnek olarak Şekil 4.1. ve Şekil 4.2 için değişken olarak seçilen girdi uçuş yüksekliği (YÖA) iken, Şekil 4.3. için değişken olarak seçilen girdi parametresi, kullanılan İHA türü olarak belirlenmiştir.



Şekil 4.2. Döner kanatlı İHA ile Test Alanı A'dan elde edilen örnek SAM, ortomozaik üretimi ve eşyüksekti eğrileri



Şekil 4.3. Döner kanatlı İHA ve sabit kanatlı İHA ile Test Alanı A'dan elde edilen örnek SAM, ortomozaik üretimi ve eşyükselti eğrileri

4.2.1. İHA görüntülerinin fotogrametrik olarak kullanılabilirliği ve dengeleme sonuçları

Bu çalışma kapsamında toplamda elli üç adet farklı özellikleri olan uçuş planlaması gerçekleştirilmiştir. Tüm uçuşlarda yersel ölçümlerle (CORS RTK ile) tesis edilen YKN'ler blok dengelemeye dâhil edilebilir şekilde ölçülmüştür (Inal ve ark 2018). Bu şekilde yaklaşık üç yüz adet YKN fotogrametrik koşullarda araziye işaretlenmiştir ve koordinat ölçümleri yapılmıştır. YKN ölçümleri dengelemelerin doğruluğunu yükseltmek ve yer-referanslı sonuç ürünler üretebilmek için kullanılmıştır.

Arazi çalışmaları sırasında oluşturulan YKN'lerin jeodezik ölçümlerinde kullanılan Tusaga Aktif (CORS RTK) yönteminin kendi içerisinde sağladığı bilinen doğruluk yatayda ~3 cm ve düşeyde ~5 cm olarak belirlenmiştir. Üretilen YKN'ler fotogrametrik sonuç ürün üretimi için blok dengelemede kullanılmıştır. YKN'ler kendi içlerinde bloktaki homojen dağılımın sağlanabileceği şekilde dengeleme-denetleme noktaları olarak ayrılmıştır.

Bu çalışmada gerçekleştirilen İHA uçuşlarının optimizasyona konu olabilmesi için sonuç ürünlerin BÖHHBÜY 2018 yönetmeliğinde belirlenen ilgili maddelere uyup uymadıkları araştırılmıştır. YKN'lerin dengelemede kullanılacağı ve sonuç ürün doğruluğuna direkt etki edeceğini göz önünde bulundurarak aşağıdaki hususlara;


- ❖ YKN dağılımına ve CORS ile nokta okumalarının yeterli düzeyde gerçekleştirilmiş olmasına (Forlani ve ark 2018),
- ❖ Yeterli sayıda YKN üretilmiş olmasına,
- ❖ Operatör hatalarının en düşük düzeyde olmasına,
- ❖ Arazi çalışmalarında yapılan insan kaynaklı hataların, elektronik ölçme aleti kaynaklı hataların mümkün olduğunca azaltılmasına ve
- ❖ İHA'larda bulunan profesyonel olmayan GNSS/IMU ekipmanının koordinat ölçümlerinde ve dengelemede özenle hesaba katılmasına (Koksal ve ark 2019) dikkat edilmiştir.

Bu çalışmada öngörülen hata kaynaklarının bazılarına benzer sorunlar yaşayan başka çalışmalarda objelerin farklı uçuş yüksekliklerinde (YÖA farklı) yapısını koruyamadığı belirlenmiştir. Hatalarla ilgili olarak hata değerinin uçuş yüksekliği ile birlikte artış gösterdiği anlaşılmaktadır (Akay ve ark 2020). Araştırmalarda karşılaşılan başka bir hata ise, İHA görüntülerinden üretilen 3B modelin köşelerine ve görüntülerin kenarlarına doğru, konumsal doğruluğun azalmasıdır (Hung ve ark 2019). Arazide homojen olarak atılması planlanan YKN'lerin farklı uçuş yüksekliklerinden üretilen sonuç ürünlerde yeterli sayılan sıklığını yitirmesi de farklı bir hata kaynağı olarak söylenebilir. Bu bilgiler göz önünde bulundurularak yapılan çalışmalarda bahsedilen hata kaynaklarından kaçınmaya özen gösterilmiştir.

Şekil 4.4'de görülen dengeleme sonucunda oluşan KOH'lar ve YKN'lerin dağılımı sonuç ürünlerden üretilen dengeleme raporlarını meydana getiren temel unsurlar olarak gösterilmiştir. Çizelge 4.9'a göre yapılan çalışmalar sonucunda elde edilen KOH (x), KOH (y) ve KOH (H) değerlerinin test alanları içerisinden seçilen örnekleri belirtilmiştir. Çizelgenin en sol sütununda Test Alanı A-B-C için ortak olarak (bu üç test

alanı da Karapınar İlçe'sinde olduğu için) belirlenmiş 07.08.2018 tarihli bir uçuştan üretilen sonuç ürünün (İHA Tipi; Döner Kanatlı İHA, YÖA; 2.75 cm/pik, Bindirme Oranları; %70 - %65 ve Atmosferik Koşul; 8 m/sn) sonuçları gösterilmiştir. İkinci sütun ve sonraki sütun ise Test Alanı D ve Test Alanı E için 10.10.2018 tarihli bir uçuştan üretilen sonuç ürünün (İHA Tipi; Döner Kanatlı İHA, YÖA; 1.95 cm/pik, Bindirme Oranları; %80 - %72 ve Atmosferik Koşul; 9 m/sn) sonuçlar ile 04.07.2018 tarihli bir uçuştan üretilen sonuç ürünün (İHA Tipi; Döner Kanatlı İHA, YÖA; 2 cm/pik, Bindirme Oranları; %70 - %60 ve Atmosferik Koşul; 4 m/sn) sonuçlarını göstermektedir. Denetleme ve kontrol noktaları için konum ve yükseklik hatalarının gösterildiği örnek çizelgeden de görüldüğü üzere sonuç ürünlerin çalışmanın amacına tezatlık barındırmadığı belirlenmiştir.





Şekil 4.4. Yazılımda dengeleme sonucunda kontrol noktaları oluşan hatalar ve YKN'lerin dağılımı

Çizelge 4.9. YKN konum ve yükseklik hataları

Test Alanı A-B-C (Örnek Dengeleme Raporu)		Test Alanı D (Örnek Dengeleme Raporu)		Test Alanı E (Örnek Dengeleme Raporu)	
Denetleme Noktaları Sayısı	4	Denetleme Noktaları Sayısı	5	Denetleme Noktaları Sayısı	8
Denetleme Noktalarının KOH (x)	3.84 cm	Denetleme Noktalarının KOH (x)	3.01 cm	Denetleme Noktalarının KOH (x)	4.38 cm
Denetleme Noktalarının KOH (y)	3.55 cm	Denetleme Noktalarının KOH (y)	2.67 cm	Denetleme Noktalarının KOH (y)	4.07 cm
Denetleme Noktalarının KOH (H)	4.24 cm	Denetleme Noktalarının KOH (H)	3.97 cm	Denetleme Noktalarının KOH (H)	5.66 cm

4.3. Optimizasyon problemi ve İHA için uçuş parametreleri optimizasyonu

Optimizasyon için algoritma seçimi ve analizler yapılırken;

- ❖ Problemin belirlenmesi,
- ❖ Literatür taraması,
- ❖ Çözümlerin araştırılması,
- ❖ Uygun amaç/maliyet fonksiyonlarının araştırılması,
- ❖ Problem ile algoritma ilişkilerinin belirlenmesi,
- ❖ Algoritmaya karar verilmesi ve
- ❖ Algoritmanın bulduğu sonuçların irdelenmesi sıralamasıyla hareket edildi.

Optimizasyon çalışmaları kapsamında test alanlarında yapılan uçuşlarda; arazinin topografik yapısı, topografik eğimler, bitki ve ürün yapısı/türü, suyla kaplı alanların durumu vb. durumları göz önünde bulundurarak araştırmalar gerçekleştirilmiştir (Makineci 2016, Manconi ve ark 2019, Verheyden ve ark 2019, Sanz-Ablanedo ve ark 2020). Bu çalışmada ortaya çıkış amacına uygun olarak fotogrametrik amaçlı harita yapımı için kullanılan İHA'ların batarya kullanımlarının ve havada kalma sürelerinin optimize edilmesi amaçlanmıştır. İHA fotogrametrisinde batarya durumunu ve uçuş süresini direkt etkileyen optimizasyon parametreleri aşağıdaki gibi sıralanmıştır:

- I. İHA seçenekleri (sabit kanatlı veya döner kanatlı),
- II. YÖA (uçuş yüksekliği ile YÖA arasındaki ilişkiye göre, 100 m – 4 cm/pik; 50 m – 2 cm/pik gibi),
- III. Bindirme oranları (sabit YÖA-farklı yan/ileri bindirme oranları; 4cm/pik YÖA ile %70 ileri %60 yan bindirme oranlı uçuş, 4cm/pik YÖA ile %80 ileri %60 yan bindirme oranlı uçuş vb.),
- IV. Atmosferik koşullar (rüzgâr koşulları, sıcaklık koşulları, yağmur/kar gibi yağış koşulları, güneşin geliş açısı vb.),
- V. İHA'nın havada kalma süresi (Uçuş süresi) ve
- VI. İHA bataryasının yapılan işlemler süresince değişimi (Batarya durumu).

Uçuş planlaması, İHA fotogrametrisinde zorlu bir süreç olarak göze çarpmaktadır. Kullanılan donanımların doğruluğu, teknik özellikleri, kapasitesi, bataryaların ömrü, arazinin topografik yapısının özellikleri ve atmosferik koşullar başarılı bir uçuş

planlaması açısından optimizasyon gerektirir (Zhang ve ark 2010, Zhang ve ark 2016, Chiang ve ark 2019, Dewangan ve ark 2019, Manconi ve ark 2019). Bu anlamda, İHAS'nin uçuş süresini etkileyen parametrelerin doğru belirlenmesi çok değişkenli bir problem olarak görülmüştür. Kullanılacak İHA donanımın türünü belirlemek, uçuş yüksekliği belirlemek, bindirme oranlarını belirlemek gibi lineer parametrelerin yanında atmosferik koşulların etkisinin bilinmemesi veya tahmin edilebilir olmaması gibi lineer olmayan tercihler yapmak da bu problemin çözümünde etken olduğu tespit edilmiştir. Uçuş süresi ve batarya durumunun benzer uçuşlarda farklı sonuçlar vermesi bu nedenlere bağlı olduğu düşünülmüştür.

Atmosferik koşullar olarak, İHA'ları etkileyen temel parametre rüzgâr olarak bilinir (Cho ve ark 2018, Coombes ve ark 2019). Basınç, nem, sıcaklık gibi farklı atmosferik koşulların da etkisi olduğu bilinmekle beraber optimizasyon uygulamalarında kayıt altına alınması mümkün olan en önemli parametre rüzgar parametresi olduğundan optimizasyona dahil edilmiştir. Bağımsız olarak tüm girdi parametrelerin çıktı parametrelerine etkisinin araştırıldığı bu çalışmada lineer olmayan girdilerin YSA kullanılarak optimize edilmesi sağlanmıştır.

4.3.1. Optimizasyon için YSA algoritmasının kullanımı

Mühendislik araştırmalarında fonksiyonlar (maliyet ve sınırlama) modelleme açısından anlaşılır ve kolay tasarlanabilir olmayabilir. Bu tarz lineer olmayan optimizasyon ihtiyaçlarında sistematik nümerik yaklaşımlar tercih edilmektedir. Bu yöntemler kısaca problem çözümlerinde bir başlangıç çözümü üzerinden iteratif olarak optimuma yakınsamaktadır (Kubat 2013, Yılmaz 2017). Optimizasyon için algoritma seçimi ve analizler yapılırken;

- ❖ Problemin belirlenmesi,
- ❖ Literatür taraması,
- ❖ Çözümlerin araştırılması,
- ❖ Uygun amaç/maliyet fonksiyonlarının araştırılması,
- ❖ Problem ile algoritma ilişkilerinin belirlenmesi,
- ❖ Algoritmaya karar verilmesi ve
- ❖ Algoritmanın bulduğu sonuçların irdelenmesi sıralamasıyla hareket edilmiştir.

Bu çalışmada denetimli regresyon modeli, YSA kullanılmıştır. Çünkü öğrenme veri setinin, tahmin edilmesi gereken yanıt faktörünü kapsaması gereklidir (Doğan ve ark

2007). Denetimli öğrenme çalışmalarında, model performansı, model tarafından belirli bir soruna önerilen çözümlerin ne kadar etkili bir şekilde uygulanabileceğini (tahmin, sınıflandırma, anormallik tespiti, vb.) ifade eder. Her konu için amaçlar çeşitlendirilebildiğinden, modelin performansının ölçülmesi farklı kriterlere dayanmaktadır. Bu kriterler genel olarak model duyarlılığı, modelin doğruluğu, ROC eğrisi şeklinde ifade edilebilir (Altun ve ark 2019).

YSA genellikle farklı algoritmalarla kullanılabilir. İyi bir algoritma basit ve konuya uygun olmalıdır (Khan ve ark 2018, Mercier ve ark 2018, Okkan ve ark 2018). Bu çalışmada literatürde önemli eğitim algoritmaları olarak kabul edilen GD Algoritması ve LM Algoritması kullanılmıştır.

4.4. Optimizasyon ve Bulguları

Hava fotogrametrisi gibi İHA fotogrametrisinde de uçuş planlaması zorlu bir süreçtir. Kullanılan araçların batarya özellikleri, uçuş planlaması ve uçuşu gerçekleştirecek kişilerin deneyimi, arazinin topografik özellikleri, arazi örtüsü ve atmosferik koşulların tespitinin uygun şekilde yapılması bir optimizasyon süreci gerektirir. Benzer şekilde, İHA uygulamalarında uçuş süresini etkileyen parametrelerin doğru belirlenmesi çok değişkenli bir sorundur (Egels 2001, Linder 2009, Haala ve ark 2011, Fahlstrom ve Gleason 2012, Gandor ve ark 2015).

YSA tekniğinin güçlü yönleri olarak, iyi bir öğrenme yeteneğinin olması, doğrusal olmayan problemleri çözebilir olması, paralel çalışabilir olması, kendi sistemini tasarlayabilmesi, sağlam (robust) olması ve hata toleransının yüksek olması olarak söylenebilir. YSA'nın zayıf yönleri ise, öğrenme süresinin beklenenden uzun olabilmesi, eğitim verilerinin miktarına ve kalitesine çok bağımlı olması, eğitim sırasında yerel minimumlara takılma riski taşınması ve istatistiksel güven aralığı, hipotez testi gibi istatistiksel özelliklere uyumlu olmaması olarak bilinir (Goudos ve ark 2019, Konar 2019, Wai ve Prasetya 2019). YSA kullanılırken temel işlem adımları şu şekilde gerçekleştirilmiştir:

I. Veri toplama (hazırlama) adımı;

Araziden toplanmış İHA uçuşlarının anlaşılır şekilde listelenmesi adımıdır. Bu adım arazide elde edilen sonuçların (uçuş deneylerinin) kaydedilmesiyle başlamaktadır. Kaydedilen uçuşlar optimizasyon probleminin çözümü için kullanılamayacak düzeyde yalındır. Bu aşamada, yapılan İHA uçuşlarından optimizasyon için gerekli parametreler

belirlenerek optimizasyon modeli oluşturmak için yeni bir çizelge haline getirildi. Burada amaç daha önce yapılan deneylerden elde edilen gözlemlerin İHA'nın havada kalma süresine direkt etki edenlerini belirlemek ve gereksiz girdi-çıkıtı parametrelerinin modele tanımlanmasından kaçınmaktır (Karaboğa 2017).

Bu çalışma kapsamında, farklı İHA donanımları kullanılarak değişken yüksekliklerde uçuşlar yapılarak; batarya durumu (uçuş öncesi ve sonrası), atmosferik koşullar (yaklaşık olarak), YÖA ve bindirme oranları ile optimizasyon şeması oluşturulmuştur. Bu uçuş verilerinden bir verimlilik modeli üretilmiştir. Bu modelin oluşturulmasında; girdi değerlerin ağırlıkları (tahmin sonuçlarının değerlendirilmesiyle), elde edilen deneyimler ve karşılaşılan sorunlara getirilen çözümler, temel dayanaklar olarak kullanılmıştır. Çizelge 4.10'da görüldüğü üzere girdi parametreleri olarak 53 farklı uçuştan üretilen öznitelikler kullanılmıştır. İHA türü ve bindirme oranları gibi nümerik olmayan girdilerin algoritma tarafından tanınabilmesi için Çizelge 4.10'da görüldüğü gibi bunlar nümerik değerlerle tanımlanmıştır. Bu girdiler listesinde öncelikle uçuşlar numaralandırılmıştır. Uçuşlar, rastgele atanmış alfabetik ve nümerik olarak (A1, B1, C1, ... gibi) kodlanmıştır.

Çizelge 4.10. Optimizasyonda kullanılan girdi verileri ve kullanım amaçları

ID	Uçuş Numarası	İHA Tipi	YÖA (cm/pik)	Bindirme Oranları (İleri/Yan,%)	Atmosferik Koşullar (Rüzgâr, km/sa.)	Uçuş Süresi (dk.)	Batarya Durumu (% Uçuş Sonrası)	Veri Tipi
1	A2	Sabit Kanatlı (1)	3	70 / 60 (1)	9	24,06	55	Test Verisi
2	C1	Sabit Kanatlı (1)	3,8	60 / 40 (2)	11	19,48	62	Test Verisi
3	H1	Sabit Kanatlı (1)	2,3	80 / 65 (3)	28	18	62	Test Verisi
4	B2	Döner Kanatlı (0)	2,5	70 / 60 (1)	5	14	40	Test Verisi
5	D1	Döner Kanatlı (0)	3	60 / 40 (2)	14	12	50	Test Verisi
6	D3	Döner Kanatlı (0)	2	60 / 40 (2)	10	16,06	35	Test Verisi
7	F2	Döner Kanatlı (0)	2,5	80 / 65 (3)	22	22,24	26	Test Verisi
8	G1	Döner Kanatlı (0)	2,45	80 / 72 (4)	15	6,14	69	Test Verisi
9	G10	Döner Kanatlı (0)	2,2	80 / 72 (4)	14	7,05	70	Test Verisi
10	Y1	Döner Kanatlı (0)	3,3	70 / 65 (6)	16	18,28	47	Test Verisi
11	N1	Döner Kanatlı (0)	1,35	80 / 72 (4)	9	14,02	49	Test Verisi
12	G9	Döner Kanatlı (0)	2,2	80 / 72 (4)	8	8,36	65	Test Verisi
13	J2	Döner Kanatlı (0)	2,75	80 / 72 (4)	28	22,39	25	Test Verisi
14	K2	Döner Kanatlı (0)	3,3	80 / 72 (4)	35	16,09	35	Test Verisi
15	T1	Döner Kanatlı (0)	3,3	70 / 65 (6)	17	13,45	46	Test Verisi
16	A1	Sabit Kanatlı (1)	3,8	70 / 60 (1)	8	16,24	58	Eğitim Verisi
17	B1	Sabit Kanatlı (1)	2,5	70 / 60 (1)	6	29,36	45	Eğitim Verisi
18	C2	Sabit Kanatlı (1)	3	60 / 40 (2)	12	26,42	50	Eğitim Verisi
19	D2	Sabit Kanatlı (1)	3,8	80 / 65 (3)	16	31,18	42	Eğitim Verisi
20	E1	Sabit Kanatlı (1)	2,5	80 / 65 (3)	15	33,54	36	Eğitim Verisi
21	E2	Sabit Kanatlı (1)	3,25	80 / 65 (3)	34	21	59	Eğitim Verisi
22	G1	Döner Kanatlı (0)	3	70 / 60 (1)	8	12,3	47	Eğitim Verisi
23	G8	Döner Kanatlı (0)	2	70 / 60 (1)	4	17,48	27	Eğitim Verisi
24	G7	Döner Kanatlı (0)	2,5	60 / 40 (2)	11	13,36	42	Eğitim Verisi
25	G8	Döner Kanatlı (0)	3,5	80 / 65 (3)	22	20,12	30	Eğitim Verisi
26	G9	Döner Kanatlı (0)	2	80 / 65 (3)	20	24,3	20	Eğitim Verisi
27	H1	Döner Kanatlı (0)	1,9	80 / 72 (4)	10	9,55	58	Eğitim Verisi

Çizelge 4.10. Optimizasyonda kullanılan girdi verileri ve kullanım amaçları (devamı)

28	H2	Döner Kanatlı (0)	2,75	70 / 63 (5)	6	12,37	49	Eğitim Verisi
29	J1	Döner Kanatlı (0)	1,9	70 / 63 (5)	5	7,46	66	Eğitim Verisi
30	J2	Döner Kanatlı (0)	1,9	70 / 63 (5)	5	9,34	56	Eğitim Verisi
31	K1	Döner Kanatlı (0)	2,45	70 / 63 (5)	4	14,51	46	Eğitim Verisi
32	K2	Döner Kanatlı (0)	1,95	80 / 72 (4)	9	7,41	68	Eğitim Verisi
33	L1	Döner Kanatlı (0)	3	70 / 65 (6)	22	13,03	50	Eğitim Verisi
34	L2	Döner Kanatlı (0)	3,3	70 / 65 (6)	17	12,05	59	Eğitim Verisi
35	M1	Döner Kanatlı (0)	2,75	80 / 72 (4)	16	5,12	73	Eğitim Verisi
36	M2	Döner Kanatlı (0)	2,75	80 / 72 (4)	18	6,42	67	Eğitim Verisi
37	N1	Döner Kanatlı (0)	2,2	80 / 72 (4)	14	9,01	62	Eğitim Verisi
38	O1	Döner Kanatlı (0)	2,45	80 / 72 (4)	19	4,41	77	Eğitim Verisi
39	O2	Döner Kanatlı (0)	1,35	80 / 72 (4)	12	9,57	57	Eğitim Verisi
40	O3	Döner Kanatlı (0)	2,45	80 / 72 (4)	11	7,14	70	Eğitim Verisi
41	P1	Döner Kanatlı (0)	2,75	70 / 63 (5)	27	13,1	45	Eğitim Verisi
42	P2	Döner Kanatlı (0)	3,3	70 / 63 (5)	32	11,04	52	Eğitim Verisi
43	R1	Döner Kanatlı (0)	2,2	70 / 63 (5)	23	20,53	29	Eğitim Verisi
44	R2	Döner Kanatlı (0)	2,45	70 / 63 (5)	25	16,12	35	Eğitim Verisi
45	S1	Döner Kanatlı (0)	2,75	70 / 63 (5)	6	18,18	27	Eğitim Verisi
46	S2	Döner Kanatlı (0)	2,75	70 / 63 (5)	6	17,33	34	Eğitim Verisi
47	T1	Döner Kanatlı (0)	3	70 / 65 (6)	20	17,57	27	Eğitim Verisi
48	T2	Döner Kanatlı (0)	3	70 / 65 (6)	18	13,45	48	Eğitim Verisi
49	U1	Döner Kanatlı (0)	3	70 / 65 (6)	19	11,3	51	Eğitim Verisi
50	U2	Döner Kanatlı (0)	3,3	70 / 65 (6)	17	6,58	64	Eğitim Verisi
51	V1	Döner Kanatlı (0)	3,3	70 / 65 (6)	18	15,2	39	Eğitim Verisi
52	Y1	Döner Kanatlı (0)	3,3	70 / 65 (6)	16	8,46	62	Eğitim Verisi
53	Z1	Döner Kanatlı (0)	3,3	70 / 65 (6)	19	13,18	54	Eğitim Verisi

Verilerin modele tanıtılması için ayrıca rakamsal ifade içermeyen «sabit kanatlı ve döner kanatlı» ifadeleri nümerik ifadeyle tanımlanmıştır, alttaki çizelgede görüldüğü üzere bindirme oranları (çalışma boyunca sık kullanılan ileri ve yan şeklinde) ikililer halinde yine 1’den 6’ya kadar tanımlanmıştır. Çizelge 4.11’de görüleceği üzere YSA’ya veri tanıtılması için “YSA Girdi Değerleri” sütununda sadece rakamsal ifadeler tanımlanmıştır.

Çizelge 4.11. Girdi parametrelerinden bazılarının nümerik eşdeğerleri

İHA Tipi	YSA Girdi Değeri	Bindirme Oranları (İleri/ Yan %)	YSA Girdi Değeri	Bindirme Oranları (İleri/ Yan %)	YSA Girdi Değeri	Bindirme Oranları (İleri/ Yan %)	YSA Girdi Değeri
Sabit Kanatlı	1	70 / 60	1	80 / 65	3	70 / 63	5
Döner Kanatlı	0	60 / 40	2	80 / 72	4	70 / 65	6

II. Ağı oluşturma adımı;

Parametrelerin gerekli şekilsel dönüşümlerinin yapılması ve girdi-çıkış parametrelerin belirlenmesi ve ağa ilişkin parametrelerin (eğitim algoritması, maksimum epok sayısı vb.) oluşturulması aşamasıdır.

III. Ağı yapılandırma adımı;

Yapılandırma adımı, girdi ve çıktı verileri incelemeyi, ağın giriş ve çıkış boyutlarını ve gizli katmanları verilere uyacak şekilde ayarlamayı ve en iyi ağ performansını sağlayacak giriş ve çıkışları belirlemesi aşamasıdır. Yapılandırma adımı normalde eğitim verileri oluşturulduğunda otomatik olarak yapılır. Bununla birlikte, ayarlama işlevi kullanılarak manuel olarak da yapılabilir.

IV. Ağırlıkları ve biasları (eşik değerleri) hesaplama adımı;

Başlangıç ağırlıklarının atanması ve eşik değere toplama fonksiyonuyla yaklaşılması bu adımda gerçekleştirilir.

V. Ağı eğitme adımı;

Bu adımda ise girdi parametrelerinin literatüre göre (Bonnlander ve Weigend 1994, May ve ark 2011) %70-30 oranında eğitim verisi ve test verisi olarak tasnif edilmesi ve sisteme eğitim verisi-test verisi olarak atanması gerekmektedir. Burada yapılan seçim en iyi eğitim parametrelerinin belirlenmesidir (Sağıroğlu ve ark 2003, Marques 2011, Kubat 2013, Yılmaz 2017).

Çizelge 4.10'da görülen 38 adet eğitim verisi program tarafından denenerek hesaplanmıştır ve kalan 15 adet test verisi de YSA'nın tahmin değerlerinin en yüksek olduğu verilerden YSA tarafından otomatik olarak seçilerek hesaplanmıştır.

Toplam 53 adet olan verinin analizi için literatürde sıkça kullanılan %70 eğitim verisi - %30 test verisi bölümlendirilmesine göre program tarafından ayrıştırılmıştır. Literatürde başka bölümlendirmeler de vardır (%60 eğitim verisi - %40 test verisi, %80 eğitim verisi - %20 test verisi gibi). Bu bölümlendirmede tercih sebebi optimizasyon sonucunda en yüksek tahmine ulaşacak eğitim verisini belirlemektir. Bu çalışmada farklı

bölümlendirmeler de denenmiş olup, daha iyi sonuçlar vermediği belirlendiği için %70 eğitim verisi - %30 test verisi yöntemi kullanılmıştır.

Eğitim verisinin programa girdi olarak sunulmasıyla YSA optimizasyon için kendisi bir model üretmiştir. Ardından test verisinde belirlenen girdi parametreleri yazılımda tanımlanarak YSA'nın çıktı parametrelerini tahmin etmesi beklenmiştir. Bu çalışmada girdi değerleri olarak, İHA Tipi, YÖA (uçuş yüksekliği), Bindirme Oranları (BO) ve Atmosferik Koşullar (AK) algoritmaya verilerek sırasıyla Uçuş Süresi (US) ve Batarya Durumu (BD) tahminleri alınmıştır. Bu tahminler sonucu, girdi parametrelerinin sisteme etkisi belirlendi ve girdilerin ağırlıkları saptanmıştır. Girdi parametrelerinin sayısal değerleri öncelikle YSA için direkt kullanıma hazır olarak sunulmuştur. Bu işlem gerçekleştirildiğinde normalizasyonsuz veriler kullanıldığı için çıkan sonuçlar analiz edilmiştir. Ardından normalizasyon işlemi gerçekleştirildi. Bu şekilde girdi parametrelerinin sayısal değerleri 0 ve 1 aralığında programa tanıtılmıştır.

Normalizasyon sonrası üretilen tahmin değerleri de analiz edilerek sonuçlar karşılaştırılmıştır. Tüm girdi ve çıktı parametrelerini kapsayan genel optimizasyon modeli bu şekilde tanımlanmıştır. YSA algoritmasının tahmin değerlerini farklı eğitim metotlarıyla geliştirmek için de iki farklı yöntem denenmiştir. Bunlardan birincisi Gradient Descent (GD) metodu olmuştur. Bu yöntem eğitim verisinin temel olarak en yüksek doğrulukta optimizasyon modelini bulmak amacıyla oluşturulmuştur. Maliyet fonksiyonunu en yakınsak değere indirgeyerek, asgari hatayı tespit edebilmek için literatürde önemli bir yeri olan GD metodu kullanılır (Mercier ve ark 2018). Normalizasyon öncesi ve sonrası tüm girdi parametreleri ile çıktı parametreleri tanımlanmış modelden en yakınsanmış maliyet fonksiyonu hesaplanarak optimizasyon gerçekleştirilmiştir. Bir diğer alternatif yöntem ise (YSA için) Levenberg-marquardt metodudur (Okkan ve ark 2018).

VI. Ağı doğrulama adımı;

Bu aşama belirlenen tüm fonksiyonların ve biasların gözden geçirildiği ve çıktı parametrelerinin uygunluğunun YSA tarafından belirlendiği, uygun değilse geri yayılım ile işlemlerin tekrarlandığı bölümdür. Yanlış fonksiyon seçiminde geri yayılım, zamansal ve tahmin doğruluğu açısından negatif etki göstermektedir.


VII. Ağı kullanma adımı,

Ağ doğrulaması olumlu sonuçlanırsa eğitim tamamlanmış ve test aşamasına geçilmiş olur (Sağıroğlu ve ark 2003, Marques 2011, Kubat 2013, Yılmaz 2017).


Tüm girdi parametrelerinin tanımlandığı, normalizasyon yapılmayan veriler ile tahminler ve normalizasyon yapılan verilerle bunların tahminleri sonucunda optimizasyon modelleri ve girdilerin ağırlıkları belirlenmiştir. Ardından girdi parametreleri ile yazılıma dahil edilmeyen yeni modeller üretilmiştir. Bu yeni modellerden de yeni tahminler üretilerek elde edilen sonuçlar, tüm girdi parametrelerinin dâhil olduğu sonuçlarla karşılaştırılmıştır. YSA performansını LM ve GD algoritmaları için değerlendiren Çizelge 4.12’den de anlaşılacağı üzere iterasyon sayıları ve gradyan değerleri normalizasyon işlemi sonrasında daha da iyileştirilmiştir.

Şekil 4.5.ve Şekil 4.6 incelendiğinde normalizasyon işlemi sonrasında eğitim ve test değerlerinde daha tutarlı sonuçlar ortaya çıktığı gözlenmiştir. Özellikle LM algoritması ile yapılan eğitimlerde normalizasyon eğitimi sonuçları önemli ölçüde değiştirirken, GD algoritması uygulamasında da önemli farklılıklar sağlanmış ve ağ iyileştirilmiştir.

Tahmin sonuçlarının yüzdesinin, kestirim sonuçlarının yüzdesine oranını gösteren regresyon analizlerinde, tüm girdiler kullanılarak yapılan testte %88 oranda başarıya ulaşılmıştır (Şekil 4.7). Girdi parametrelerinde tek tek optimizasyona dâhil edilmediği regresyon analizlerinde ise Atmosferik Koşullar (AK) girdisi olmayan modelin tahmin yüzdesinin %67’ye kadar gerilediği görülmüştür. Eğitim için kullanılan verinin test için kullanılan veriyle olan uyumları da analiz edildiğinde İHA türü, YÖA ve BO girdilerinin modele benzer uyumlu sonuçlar verdiği görülmüştür



Şekil 4.5. YSA eğitim ve test sonuçları (normalizasyon öncesi solda ve normalizasyon sonrası sağda GD algoritması)



Şekil 4.6. YSA eğitim ve test sonuçları (normalizasyon öncesi solda ve normalizasyon sonrası sağda LM algoritması)

Şekil 4.6'ya göre normalizasyon öncesi GD Algoritması ile yapılan eğitim işlemi sonrası regresyon değeri $R=0.90$ çıkararak yüksek doğrulukta tahmin gerçekleştirmiştir. GD yönteminin normalizasyon sonra eğitim sonucu tahmin değerini gösteren $R=0.86$ ya düşmüştür. LM Algoritması için ise normalizasyon çok önemli bir kırılmaya sebep olmuştur. LM yöntemi uygulanarak yapılan eğitim setine göre tahmin sonuçlarını gösteren regresyon değeri $R=0.49$ olarak tespit edilmiştir. Normalizasyon sonrası ise regresyon değeri tahmin sonuçlarındaki artışın ne kadar yüksek olduğunu göstermiştir ($R=0.90$). Ayrıca tahminlerin tutarlılığını gösteren en önemli gösterge olan uyum doğrusu (fit line) kontrol edildiğinde GD yöntemi için normalizasyon işlemi çok olumlu sonuçlar oluşturmazken, LM algoritması için normalizasyon uyum doğrusunun çok iyileşmesine sebep olmuştur (Sağıroğlu ve ark 2003, Kubat 2013, Karaboğa 2017). Buna neden olarak ise LM Algoritmasının en uygun eğri uydurma yöntemlerinin bir birleşimi olması gösterilebilir (Gradient Descent ve Gauss-Newton yöntemleri). Bu sebeple de normalizasyon ihtiyacı duymaktadır. GD yöntemi en dik iniş yönündeki parametreleri sürekli yenileyerek hataların karesini en düşük tutmaya çalışır. LM ise parametreler optimum değerlerine yakın değil ise GD algoritması gibi davranmaktadır (Levenberg 1944, Marquardt ve Mathematics 1963, Khan ve ark 2018, Mercier ve ark 2018).

Çizelge 4.12. Algoritma performansları

Normalizasyon Öncesi	Algoritma	İterasyon	Öğrenme Oranı	μ	Gradyan Değeri
	Gradient Descent	1500	0,00028439	-	6,1687
	Levenberg-marquardt	1090	-	0,001	0,37305
Normalizasyon Sonrası	Algoritma	İterasyon	Öğrenme Oranı	μ	Gradyan Değeri
	Gradient Descent	1047	0,0012713	-	11,3828
	Levenberg-marquardt	1009	-	0,001	0,02694

Bir fonksiyonun kısmi türevlerinin vektörünü ifade etmek için kullanılan gradyan değeri GD ve LM algoritmaları için normalizasyon öncesi sırasıyla 6.1687 ve 0,37305 olarak belirlenmiştir. Normalizasyon işlemi tamamlandıktan sonra ise GD için 11.3828 olarak yaklaşık yüzde doksan oranında artış görülmüştür (Çizelge 4.12). LM algoritması için ise normalizasyon işleminden sonra gradyan değerinin 0,02694 olduğu görülmüştür.

LM algoritmasının karakteristik yapısından dolayı yaklaşık 0.07 bir değer azalış eğilimi gösterdiği belirlenmiştir.


Çizelge 4.13. Eğitim verisiyle eğitilmiş algoritmaların test verisi tahmin sonuçları

Tahmin Sonucu/Algoritma Türü	Normalizasyon Öncesi		Normalizasyon Sonrası	
	GD Algoritması	LM Algoritması	GD Algoritması	LM Algoritması
Ortalama Uçuş Süresi (US) Tahmini (Tüm Girdiler Dahil)	71,12%	65,75%	77,65%	56,68%
Ortalama Batarya Durumu (BD) Tahmini (Tüm Girdiler Dahil)	73,89%	58,80%	80,91%	66,80%
Ortalama Uçuş Süresi (US) Tahmini (İHA Tipi Girdisi Hariç)	71,83%	60,89%	60,43%	60,53%
Ortalama Batarya Durumu (BD) Tahmini (İHA Tipi Girdisi Hariç)	81,55%	78,07%	66,60%	58,92%
Ortalama Uçuş Süresi (US) Tahmini (YÖA Girdisi Hariç)	67,53%	71,36%	60,18%	48,43%
Ortalama Batarya Durumu (BD) Tahmini (YÖA Girdisi Hariç)	72,09%	77,76%	70,21%	51,35%
Ortalama Uçuş Süresi (US) Tahmini (BO Girdisi Hariç)	61,69%	31,54%	74,29%	55,60%
Ortalama Batarya Durumu (BD) Tahmini (BO Girdisi Hariç)	72,53%	32,21%	76,25%	72,20%
Ortalama Uçuş Süresi (US) Tahmini (AK Girdisi Hariç)	63,84%	18,87%	65,10%	55,29%
Ortalama Batarya Durumu (BD) Tahmini (AK Girdisi Hariç)	57,92%	71,96%	73,41%	66,82%

Girdi parametrelerinin optimize edilmesiyle tahmin çıktılarının oluşturulduğu Çizelge 4.13'e göre en sağdaki iki sütun normalizasyon yapılmış ve onların solundaki iki sütun ise normalizasyon yapılmamış verilerle üretilen sonuçlardan oluşturulmuştur. Çizelgede en üst iki satırda tüm girdilerin kullanıldığı durumda Uçuş Süresi ve Batarya Durumu tahmini gösterilmiştir. Bu iki satır için yüzde 81 tahmin ile GD algoritmasının normalizasyonlu verilerle gerçekleştirdiği görülmüştür. Devamındaki iki satırda İHA Tipi girdi olarak kullanılmadığında elde edilen sonuçlar verilmiştir. Bu sonuçlara göre de normalizasyonsuz GD algoritması yüzde 82 ile en yüksek tahmin yüzdesine ulaşmıştır. Sonraki iki satırda ise YÖA girdi olarak kullanılmadığında elde edilen sonuçlar

gösterilmiştir. Bu sonuçlara göre de normalizasyonsuz LM algoritması yüzde 78 ile en yüksek tahmin yüzdesine ulaşmıştır. Bindirme Oranı girdi olarak kullanılmadığında elde edilen sonuçlarda ise yüzde 76 tahmin ile GD algoritmasının normalizasyonlu verilerle gerçekleştirdiği anlaşılmıştır. Son iki satırda ise Atmosferik Koşulların girdi olarak kullanılmadığında elde edilen sonuçlara göre yüzde 73 tahmin ile GD algoritmasının normalizasyonlu verilerle gerçekleştirdiği tespit edilmiştir.

Normalleştirilmiş veriler tüm girdi parametreleri optimizasyona dâhil edilerek kullanıldığında, GD algoritması uçuş süresi tahmininde %77,65 doğruluğa ulaştığı görülmüştür (Çizelge 4.11). Batarya Durumu (BD) çıktısında, aynı algoritma normalleştirilmiş verileri uygulayarak %80.91 tahmin doğruluğuna ulaşılmıştır. İHA Tipi, YÖA, BO ve AK girdilerinde herhangi biri kullanılmadan yapılan tahminlerde farklı durumlar ortaya çıkmıştır. Örneğin YÖA girdisi dâhil edilmeden tahmin doğruluğu ile normalizasyon öncesi verilerde LM algoritması başarılı olurken, GD algoritması normalizasyon sonrası daha etkili sonuçlar vermiştir. Buna rağmen, normalizasyon genel olarak olumlu bir katkı sağlamıştır. Literatür çalışmalarında da optimizasyonun olumlu sonuçlar ortaya çıkardığı bilinmektedir (Yavuz ve Deveci 2012, Ioffe ve Szegedy 2015).



Şekil 4.7. Regresyon sonuçları

Regresyon sonuçları da (Şekil 4.7), tm girdilerin dâhil edildiđi tahmin yzdesi %87,8 olarak belirlenmiřtir. Tahmin bařarısı en ok BO girdisinin kaldırılmasından etkilenmiřtir (%80,4). Literatr arařtırmasında belirlenen optimizasyon alıřmalarına bakılarak sonular deđerlendirildiđinde YSA iin GD ve LM algoritmaları karřılařtırma

yapmak için başarılı eğitim yöntemleri olarak belirlenmiştir. Evrişimsel sinir ağları (ESA), genetik algoritma gibi tahmin yöntemlerine göre YSA'nın daha başarılı olacağı öngörüsü olumlu sonuç vermiştir. YSA ile yapılan alternatif çalışmalarda yeterli veri çokluğunun sağlanamadığı durumlarda optimizasyon için kullanılabilir nitelikte olduğu kabul edilir (Sağıroğlu ve ark 2003, May ve ark 2011, Kubat 2013, Karaboğa 2017, Toraman 2018).

Ayrıca dört girdi ve üç çıktı parametresine sahip olan bir verinin YSA ile optimizasyonundan elde edilen sonuçlar ile yapılan uçuş süresi optimizasyonunda YSA ile İHA verileri arasında bir uyumluluk olduğu iddia edilmektedir (Konar 2019). YSA ile yapılan tahmin optimizasyonunda çalışma sonunda ortaya çıkan bulgular, tahminlerin yeterli doğrulukta olduğunu belirlemek ve problemin çözümüne uygun olduğunu tespit etmek için uygun görülmüştür.

YSA ile kombine edilen stokastik çok nesneli optimizasyon modeli hesap süresi ve en uygun sonucu bulma açısından %33 daha az sürede daha fazla sayıda (yaklaşık %80) geçerli çözüm ürettiği bilinmektedir (Azabi ve ark 2019). Buna ek olarak İHA görüntüleri ile yapılan araştırmalarda -0,7 mm ortalama hata ve 16,3 mm standart sapma ile YSA tahmin sonuçları verdiği bilinmektedir (Takeuchi ve Nakanishi 2019). Benzer araştırmaları da göz önünde bulundurarak geliştirilen YSA modeli, çıktı parametre olarak belirlenen Batarya Durumu (BD) tahmininde yüksek tahmin yüzdesine ulaşarak çalışmanın amacına uygunluğunu göstermiştir.

Çizelge 4.14. Uçuş süresi ve batarya durumu için girdilerin ağırlıkları

Ağırlık	Uçuş Süresi Tahmini İçin (%)	Batarya Durumu Tahmini İçin (%)
İHA Tipi Girdisinin Ağırlığı	3,36	28,64
YÖA Girdisinin Ağırlığı	17,10	6,71
BO Girdisinin Ağırlığı	44,90	5,04
AK Girdisinin Ağırlığı	34,64	59,61
Toplam	100	100

Çıktı parametrelerin belirlenmesinde etkili olan girdi parametrelerin ağırlıklarında ise Çizelge 4.14'e göre uçuş süresi tahmini için (US çıktısı) bindirme oranları en yüksek ağırlıktaki girdi parametre olarak dikkat çekmiştir. US çıktısı için tahmin ağırlığı en düşük olan ise %3.36 ile İHA tipi girdisi olarak tespit edilmiştir. Batarya Durumu tahmini (BD çıktısı) için ağırlıklara bakıldığında ise en düşük etkiyi BO girdisi %5.04 ile göstermiştir. Fakat BD çıktısı için en büyük ağırlık değerine sahip girdi atmosferik koşullar (AK girdisi) olduğu belirlenmiştir (%59.61). Girdi parametrelerin yapılan işlemler sonucunda elde edilen ağırlıklarını gösteren Çizelge 4.14'e göre ise AK girdisinin BD için en önemli ve US çıktısı için de ikinci önemli etkiyi gösterdiği görülmüştür. İki çıktı parametresi tahminlerinin ortalamalarına göre optimizasyon modeline Ağırlıkları sırasıyla AK, BO, İHA Tipi ve YÖA olarak tespit edilmiştir. Literatürde belirlenen çalışmalarda da rüzgârın İHA üzerine önemli ölçüde etki yaptığı belirlenmiştir (Cho ve ark 2018, Coombes ve ark 2019). Bindirme oranlarının da İHA uçuş planına etkisi önemli olarak belirlenmiştir (Domingo ve ark 2019, Tjahjadi ve ark 2019, Verheyden ve ark 2019).

Çizelge 4.15. Girdilerin ağırlıkları (batarya durumu için)

Girdi Parametrelerinin Sisteme Göre Ağırlıkları	İHA Tipi - Batarya Durumu Etki Yüzdesi = %28.64	YÖA - Batarya Durumu Etki Yüzdesi = %6.71	BO - Batarya Durumu Etki Yüzdesi = %5.04	AK - Batarya Durumu Etki Yüzdesi = %59.62
İHA Tipi - Batarya Durumu Etki Yüzdesi = %28.64	1	0.2342	0.1761	0.4804
YÖA - Batarya Durumu Etki Yüzdesi = %6.71	0.2342	1	0.7518	0.1125
BO - Batarya Durumu Etki Yüzdesi = %5.04	0.1761	0.7518	1	0.0846
AK - Batarya Durumu Etki Yüzdesi = %59.62	0.4804	0.1125	0.0846	1

Çizelge 4.16. Girdilerin ağırlıkları (uçuş süresi için)

Girdi Parametrelerinin Sisteme Göre Ağırlıkları	İHA Tipi - Uçuş Süresi Etki Yüzdesi = %3.3573	YÖA - Uçuş Süresi Etki Yüzdesi = %17.0981	BO - Uçuş Süresi Etki Yüzdesi = %5.04	AK - Uçuş Süresi Etki Yüzdesi = %34.6448
İHA Tipi - Uçuş Süresi Etki Yüzdesi = %3.3573	1	0.1964	0.0748	0.0969
YÖA - Uçuş Süresi Etki Yüzdesi = %17.0981	0.1964	1	0.3808	0.4935
BO - Uçuş Süresi Etki Yüzdesi = %44.8997	0.0748	0.3808	1	0.7716
AK - Uçuş Süresi Etki Yüzdesi = %34.6448	0.0969	0.4935	0.7716	1

Çizelge 4.15 ve Çizelge 4.16 belirtildiği şekliyle ağırlıkların birbirlerine göre ve kümülatif tahmin etkisi, tüm çıktı parametreler için (US ve BD) belirlenmiştir. Çizelgelerden de görüleceği üzere Kümülatif toplamaları 1 (toplam %100) olduğu tespit edilmiştir ve doğrulaması yapılmıştır. Girdilerin BD çıktısı için etkileri de hesaplanarak Çizelge 4.15 'de gösterilmiştir. Girdilerin US çıktısı üzerine etkileri belirlenerek Çizelge 4.16 'da gösterilmiştir.

4.5. Optimizasyon Sonrası Geliştirilen GUI

Bu çalışma kapsamında, amaç olarak benimsenen düşüncüyü karşılayacak nitelikte ve ayrıca kullanıcıların daha rahat anlayıp kullanabileceği şekilde bir GUI oluşturulmuştur. Oluşturulan GUI için Çizelge 4.17'de görülen parametrelerden siyahla yazılmış parametreler (İHA Tipi, Arazi Tipi, Eğim Tipi ve YÖA) girdi olarak belirlenmiştir. Arazide yapılan deneylerin ve gözlemlerin optimizasyon modeliyle buluşturulması ve sonuçların analiz

edilmesi sonrasında problem ile ilgili bir çözüm gerçekleştirilmesi sonucuna dayananan bu GUI, bulunan çözümlerin diğer kullanıcılara da aktarılabilmesi için oluşturulmuştur. Bu grafik tabanlı arayüz, oluşturulan optimizasyon modelini baz alarak sonuçlar vermesi esasına dayandırılmıştır. Ayrıca kullanıcı tarafından kolay anlaşılabilir olarak tasarlanmıştır. GUI, Çizelge 4.17’de görülen sütunların kullanıcı tarafından aşama aşama seçilmesine ve daha önce oluşturulan optimizasyon sonuçlarına göre yüzdesel olarak en yüksek ihtimalli sonucu sunması esasına dayandırılmıştır.



Çizelge 4.17. GUI için oluşturulan girdi ve çıktı parametreleri

Girdi Parametreleri				Çıktı Parametreleri		
İHA Tipi	Arazi Tipi	Eğim Tipi	YÖA	Uçuş Yüksekliği	Bindirme Oranları (İleri/Yan)	Uçuş Süresi
Sabit Kanatlı	Kırsal Alan	Düzlemsel Alan	~1 cm/pik	30 - 50	90 / 90	~0-5 dk.
Döner Kanatlı	Kentsel Alan	Eğimli Alan	~1.3-1.75 cm/pik	50 - 65	90 / 80	~5-8 dk.
		Çok Eğimli Alan	~2 cm/pik	70 - 80	90 / 70	~8-10 dk.
			~2.3-2.75 cm/pik	85 - 100	90 / 60	~10-15 dk.
			~3 cm/pik	110 - 120	80 / 80	~15-18 dk.
			~3.3-3.75cm/pik		80 / 70	
			~4 cm/pik		80 / 60	
			~4.3-4.75 cm/pik		80 / 50	
			~5 cm/pik		70 / 70	
					70 / 60	
					70 / 50	
					60 / 60	
					60 / 50	
					60 / 40	

Şekil 4.8’de görüldüğü üzere başlangıçta ekranda uçuş simülasyon arayüzü çalıştırılmıştır. Ardından sırasıyla, İHA tipi seçerek başlanılmış, devamında arazi tipi ve eğim tipi bilgileri seçilerek devam edilmiştir. Son olarak istenen YÖA seçilmiş ve sonuç ver butonu tıklanmıştır. Sonuçta arayüz kullanıcıya daha önceki deneylere dayalı olarak seçilmesi gereken Uçuş yüksekliğini, Bindirme Oranlarını, Uçuş süresini ve üretilen bu optimizasyon modelinin tahmin doğruluğunu yüzdesel ifadeyle göstermiştir. Bu şekilde grafik sonuç veren tasarım hayata geçirilmiştir.

İHA UÇUŞ SİMÜLASYON ARAYÜZÜ

İHA Tipi: Sabit Kanat

Arazi Tipi: 1

Eğim Tipi: 2

GSD cm/pix: 1.3-1.75

Uçuş Yüksekliği (m): 70-80

Bindirme Oranı (%): 70/60

Uçuş Süresi (Dk): 8-10

Model Doğruluk (%): 92

Sonuç Ver

İHA UÇUŞ SİMÜLASYON ARAYÜZÜ

İHA Tipi: Sabit Kanat

Arazi Tipi: 1

Eğim Tipi: 2

GSD cm/pix: 1.3-1.75

Uçuş Yüksekliği (m): 70-80

Bindirme Oranı (%): 70/60

Uçuş Süresi (Dk): 8-10

Model Doğruluk (%): 92

Sonuç Ver

İHA UÇUŞ SİMÜLASYON ARAYÜZÜ

İHA Tipi: Sabit Kanat

Arazi Tipi: 1

Eğim Tipi: 2

GSD cm/pix: 1.3-1.75

Uçuş Yüksekliği (m): 70-80

Bindirme Oranı (%): 70/60

Uçuş Süresi (Dk): 8-10

Model Doğruluk (%): 92

Sonuç Ver

İHA UÇUŞ SİMÜLASYON ARAYÜZÜ

İHA Tipi: Sabit Kanat

Arazi Tipi: 1

Eğim Tipi: 2

GSD cm/pix: 1.3-1.75

Uçuş Yüksekliği (m): 70-80

Bindirme Oranı (%): 70/60

Uçuş Süresi (Dk): 8-10

Model Doğruluk (%): 92

Sonuç Ver

Şekil 4.8. İHA uçuş simülasyonu arayüzü

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

İHA'ların fotogrametrik amaçlı kullanımı geçmişe oranla çok fazla artmıştır. Bu çalışmada; İHA sistemlerinin havada kalma süreleri kısıtlı olması, uçuş sürelerinin kullanıcılar tarafından doğru tahmin edilememesi, fotogrametrik iş akışı çerçevesinde uygun planlamanın bilinmemesi problemlerine uygun bir çözüm bulunması maksadıyla araştırmalar gerçekleştirilmiştir.

Belirlenen problemin çözümü için, gerçek arazi koşullarında İHA ile yapılacak fotogrametrik temelli uçuşların planlamasında, gerçekleştirilmesinde ve sonuçlandırılmasında kullanılacak bir optimizasyon modeli kurulması amaçlanmıştır. Ayrıca bu model kullanıcılar için grafik tabanlı bir arayüze altlık olarak tanımlanması hedefi belirlenmiştir. Çalışmayı gerçekleştirmek için daha öncede arazi koşullarında oluşturulmuş hazır bir veri seti bulunmamasından dolayı deneyler gerçek arazi koşullarında gerçekleştirilmiştir.

Sezgisel veya meta-sezgisel yöntemlerin uygulanabilmesi için bir matematiksel modele ihtiyaç vardır. Bu nedenle optimizasyon karar algoritmaları ile yapılmış ve buna uygun olarak YSA kullanılarak hem literatüre hem de tahmin doğruluğunun yüksek olmasına fayda sağladığı görülmüştür. Çalışmada oluşturulan optimizasyon modeli, YSA ile tanımlanmıştır ve eğitim algoritmaları olarak literatürde en sık karşılaşılan GD algoritması ve LM algoritması kullanılmıştır.

Girdi parametreleri olarak İHA'nın havada kalma süresine direkt etki eden İHA Tipi girdisi, YÖA girdisi (uçuş yüksekliği), BO girdisi ve AK girdisi belirlenmiş ve sonuçların analizinde yüksek doğrulukta tahminlere ulaşılmıştır. Çalışma boyunca araziden elde edilen tüm optimizasyon girdileri, YSA ile eğitilip çıktılar için tahminler üretilmiştir. Çıktı parametrelerinin (tahmin sonuçları) yüksek doğrulukta sonuçlandığı tespit edilmiştir. Ayrıca girdi-çıktı parametreleri arasındaki uyumlar ve girdi parametrelerinin optimizasyondan tek tek çıkarılarak yapılan tahmin sonuçlarına etkileri incelenmiştir ve bulguların güvenilir olduğu tespit edilmiştir. Ayrıca girdi parametrelerin üzerinde normalizasyon yaparak sonuçlara etkisi araştırılmıştır. Normalize edilmiş verilerin GD algoritmasında bulunan regresyon sonuçları ile normalize edilmiş verilerin LM algoritmasında bulunan regresyon sonuçları karşılaştırılarak optimizasyona uygunlukları tespit edilmiştir.

Sonuç olarak YSA ile optimizasyon amaçlı tahmin yaptırılmış ve girdi parametrelerin sonuca etkileri araştırılmıştır. Girdi parametrelerini eğitmek için iki farklı alt algoritma denenmiş ve GD algoritmasının LM algoritmasına göre daha yüksek doğruluk verdiği belirlenmiştir. Parametrelerin tamamını kapsayan ve Normalizasyon yapılmamış veriler ile bulunan sonuçlarda BD çıktısı için yaklaşık %75 tahmin doğruluğu ortaya konulmuştur.

Parametrelerin tamamını kapsayan ve normalizasyon sonrası kullanılan veriler ile yapılan hesaplama sonunda elde edilen sonuçlarda ise BD çıktısı için yaklaşık %81 tahmin doğruluğu ortaya konulmuştur. Parametrelerin her birinin ayrı ayrı çıkarılarak yapılan araştırmada ise normalizasyon yapılmamış veriler için doğruluğun genellikle düştüğü görülmüştür. İHA Tipi girdisi hariç yapılan tahmin sonuçlarında BD çıktısı için yaklaşık %82 tahmin doğruluğuna ulaşılmıştır. AK girdisi hariç yapılan tahmin sonuçlarında BD çıktısı için yaklaşık %58 tahmin doğruluğunda olduğu ortaya konulmuştur.

Parametrelerin her birinin ayrı ayrı çıkarılarak yapılan araştırmada ise normalizasyon sonrası veriler için doğruluk kısmen düşmüştür. Bulunan sonuçlarda BO girdisi hariç yapılan tahmin sonuçlarında BD çıktısı için yaklaşık %76 tahmin doğruluğunda olup, AK girdisi hariç US çıktısı için yaklaşık %60 tahmin doğruluğunda olduğu ortaya konulmuştur (Çizelge 4.13).

Bulguların yorumlanmasıyla AK girdisinin US çıktısına ve BD çıktısına en yüksek etkiyi gösterdiği tespit edilmiştir. Fakat AK girdisi çok farklı bilinmeyenlerle (rüzgâr, rutubet, sıcaklık vb.) modellenebilir yapıda olmadığı için bu çalışmada kalkış anındaki rüzgâr parametresi atmosferik koşul olarak benimsenmiştir. Buradan anlaşılabileceği üzere kalkış anındaki rüzgârın etkisinin çok önemli bir parametre olduğu ve çıktı parametrelere önemli etkiler yaptığı görülmüştür. Girdi parametrelerin tek tek modelden çıkarılarak optimizasyonların tekrar tekrar yapıldığı araştırmalarda da sırasıyla BO, YÖA ve İHA Tipi girdi parametreleri modele en yüksek etkiyi gösteren parametreler olduğu belirlenmiştir.

Sonuç olarak çalışma kapsamında yapılan araştırmalar literatürde eksikliği hissedilen fotogrametrik temelli İHA kullanımında uçuş optimizasyonunun başarıyla yapılabildiğini göstermiştir. YZ uygulamaları kullanılarak yapılan optimizasyon sonucunda İHA'nın havada kalma süresini ve batarya kullanım durumunu tahmin

edebilen uygun sonuçlar bulunarak, çalışmanın oluşmasına sebep olan problemin çözümüne ve belirlenen amaçların tamamlanmasına ulaşılmıştır.

5.2 Öneriler

Uçuş optimizasyonu, İHA kullanımının verimli hale gelmesi ve model üretiminin bir standarda kavuşması için önemli bir araştırma konusu olarak tercih edilmiştir. Bu çalışmanın amacını oluşturan uçuş parametreleri (bindirme oranları, YÖA, atmosferik koşullar vb.) ile İHA Tipi (sabit kanatlı, döner kanatlı veya melez) ve arazi türü (tarım arazisi, kırsal arazi vb.) çalışma süresi boyunca araştırılarak sonuçlara olan etkisi tartışılmıştır. Bu verilerin analizi gerçekleştirilerek belirlenen girdi ve çıktı parametrelerinden “Uçuş Optimizasyonu” çalışması yapılabilmesi için YSA tercih edilmiştir. Son olarak yapılan “İHA Uçuş Simülasyonu” uygulaması kullanıcılara sunulabilir düzeyde bir uygulama olarak geliştirilmiştir.

Tahmin algoritması olarak kullanılan YSA başarılı sonuçlar vermektedir. YSA dışında bilinen makine öğrenmesi yöntemlerinin kullanılmasıyla sonuçlar tekrar incelenebilir ve analiz edilebilir.

Fotogrametrik amaçlı İHA kullanımında hemen hemen tüm çalışmalarda kullanılan sensör RGB kameradır. Gelecekte, fotogrametrik amaçlı uçuş optimizasyonu araştırmalarında farklı sensörlerin (Lidar, Radar gibi) kullanılarak optimizasyonun genişletilmesi de mümkündür.

KAYNAKLAR

- Adam EY, 2019. Leveraging connectivity for coverage in drone networks for target detection. *Balkan Journal of Electrical Computer Engineering*, 7, 3, 218-25.
- Akay SS, OZCAN O, ŞANLI FB, Bayram B, Görüm T, 2020. ASSESSING THE SPATIAL ACCURACY OF UAV-DERIVED PRODUCTS BASED ON VARIATION OF FLIGHT ALTITUDES. *Turkish Journal of Engineering*, 5, 1, 37-43.
- Alpaydin E, 2020. Introduction to machine learning, MIT press, p.
- Altun M, KAYIKÇI K, Irmak S, 2019. Sınıf Öğretmenliği Öğrencilerinin Mezuniyet Notlarının Regresyon Analizi ve Yapay Sinir Ağları Yöntemleriyle Tahmini/Estimation of Graduation Grades of Primary Education Students by Using Regression Analysis and Artificial Neural Networks. *e-Uluslararası Eğitim Araştırmaları Dergisi*, 10, 3, 29-43.
- Arantes MdS, Arantes JdS, Toledo CFM, Williams BC. A hybrid multi-population genetic algorithm for UAV path planning. *Proceedings of the Genetic and Evolutionary Computation Conference 2016*, 853-60.
- Austin R, 2011. Unmanned aircraft systems: UAVS design, development and deployment, John Wiley & Sons, p.
- Ayyildiz E, 2020. İnsansız Hava Araçlarının Kadastro Çalışmalarında Kullanımı. *Türkiye Fotogrametri Dergisi*, 2, 1, 29-32.
- Azabi Y, Savvaris A, Kipouros T, 2019. Artificial Intelligence to Enhance Aerodynamic Shape Optimisation of the Aegis UAV. *Machine Learning and Knowledge Extraction*, 1, 2, 552-74.
- Barba S, Barbarella M, Di Benedetto A, Fiani M, Gujski L, Limongiello M, 2019. Accuracy Assessment of 3D Photogrammetric Models from an Unmanned Aerial Vehicle. *Drones*, 3, 4, 79.
- Barba S, Barbarella M, Di Benedetto A, Fiani M, Gujski L, Limongiello MJD, 2019. Accuracy Assessment of 3D Photogrammetric Models from an Unmanned Aerial Vehicle. 3, 4, 79.
- Behnck LP, Doering D, Pereira CE, Rettberg AJI-P, 2015. A modified simulated annealing algorithm for SUAVs path planning. 48, 10, 63-8.
- Bonnlander BV, Weigend AS. Selecting input variables using mutual information and nonparametric density estimation. *Proceedings of the 1994 International Symposium on Artificial Neural Networks (ISANN'94)*, 42-50.
- Türkiye Cumhuriyeti Devleti, 2018. Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği. Resmi Gazete p. 6961-7112.
- Chen B, Pan B, 2020. Camera calibration using synthetic random speckle pattern and digital image correlation. *Opt Laser Eng*, 126, 105919.
- Chiabrando F, Lingua A, Maschio P, Losè LTJTIAoP, Remote Sensing, Sciences SI, 2017. The influence of flight planning and camera orientation in UAVs photogrammetry. A test in the area of Rocca San Silvestro (LI), TUSCANY. 42, 163.
- Chiang W-C, Li Y, Shang J, Urban TL, 2019. Impact of drone delivery on sustainability and cost: Realizing the UAV potential through vehicle routing optimization. *Appl Energ*, 242, 1164-75.
- Cho D-H, Ha J-S, Lee S, Moon S, Choi H-L, 2018. Informative path planning and mapping with multiple uavs in wind fields. In: *Distributed Autonomous Robotic Systems*. Eds: Springer, p. 269-83.

- Coombes M, Chen W-H, Liu C. Flight testing Boustrophedon coverage path planning for fixed wing UAVs in wind. 2019 International Conference on Robotics and Automation (ICRA), 711-7.
- Cryderman C, Mah SB, Shufletoski A, 2014. Evaluation of UAV photogrammetric accuracy for mapping and earthworks computations. *Geomatica*, 68, 4, 309-17.
- Ćwiąkała P, 2019. Testing procedure of unmanned aerial vehicles (UAVs) trajectory in automatic missions. *Applied Sciences*, 9, 17, 3488.
- Çoban S, Oktay T, 2018. Legal and Ethical Issues of Unmanned Aerial Vehicles. *Journal of Aviation*, 2, 1, 31-5.
- Çoban S, Oktay T, 2018. Unmanned Aerial Vehicles (UAVs) According to Engine Type. *Journal of Aviation*, 2, 2, 177-84.
- Dewangan RK, Shukla A, Godfrey WW, 2019. Three dimensional path planning using Grey wolf optimizer for UAVs. *Applied Intelligence*, 49, 6, 2201-17.
- Dewangan RK, Shukla A, Godfrey WWJAI, 2019. Three dimensional path planning using Grey wolf optimizer for UAVs. 49, 6, 2201-17.
- Doğan E, Işık S, Sandalcı MJİTD, 2007. Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi. 4119, 4131, 271.
- Domingo D, Ørka HO, Næsset E, Kachamba D, Gobakken TJRS, 2019. Effects of uav image resolution, camera type, and image overlap on accuracy of biomass predictions in a tropical woodland. 11, 8, 948.
- Duong TQ, Nguyen LD, Nguyen LK. Practical optimisation of path planning and completion time of data collection for UAV-enabled disaster communications. 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC), 372-7.
- Durdu A, Korkmaz MJAE, Engineering E, 2019. Autonomously simultaneous localization and mapping based on line tracking in a factory-like environment. 17, 1, 45-53.
- Egels Y, 2001. Digital photogrammetry, CRC Press, p.
- Ekici S, 2020. Design of Unmanned Helicopter Equipped with Turboshift Engine for Agriculture Spraying Mission Based on Thermodynamic Analysis. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10, 1, 532-46.
- Fahlstrom P, Gleason T, 2012. Introduction to UAV systems, John Wiley & Sons, p.
- Fidancı Y, Karabörk H, 2019. İnsansız Hava Araçlarının Ormanlık Alanlardaki Karayolu Projelerinde Kullanımı. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 9, 3, 473-85.
- Forlani G, Dall'Asta E, Diotri F, Cella UMD, Roncella R, Santise M, 2018. Quality assessment of DSMs produced from UAV flights georeferenced with on-board RTK positioning. *Remote Sens-Basel*, 10, 2, 311.
- Forlani G, Dall'Asta E, Diotri F, Cella UMD, Roncella R, Santise MJRS, 2018. Quality assessment of DSMs produced from UAV flights georeferenced with on-board RTK positioning. 10, 2, 311.
- Gandor F, Rehak M, Skaloud JJIAotP, Remote Sensing, Sciences SI, 2015. PHOTOGRAMMETRIC MISSION PLANNER FOR RPAS. 40.
- Gómez-López JM, Pérez-García JL, Mozas-Calvache AT, Delgado-García JJIIJoG-I, 2020. Mission Flight Planning of RPAS for Photogrammetric Studies in Complex Scenes. 9, 6, 392.
- Goudos SK, Tsoulos GV, Athanasiadou G, Batistatos MC, Zarbouti D, Psannis KE, 2019. Artificial neural network optimal modeling and optimization of UAV measurements for mobile communications using the L-SHADE algorithm. *Ieee T Antenn Propag*, 67, 6, 4022-31.

- Güçlü A, Kurtuluş DF, Arıkan KB, 2016. Sabit Ve Döner Kanatlı Hava Aracının Yönelim Dinamiklerinin Hibrit Denetimi. *Sürdürülebilir Havacılık Araştırmaları Dergisi*, 1, 2, 65-73.
- Haala N, Cramer M, Weimer F, Trittler M, 2011. Performance test on UAV-based photogrammetric data collection. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, 6.
- Haala N, Cramer M, Weimer F, Trittler MJIAotP, Remote Sensing, Sciences SI, 2011. Performance test on UAV-based photogrammetric data collection. 38, 6.
- Hernandez-Lopez D, Felipe-Garcia B, Gonzalez-Aguilera D, Arias-Perez BJPE, Sensing R, 2013. An automatic approach to UAV flight planning and control for photogrammetric applications. 79, 1, 87-98.
- Herrero-Huerta M, Rahmani SR, Rainey KM, 2020. Deep Phenotyping Considering Tile Drainage from Uas-Based Multispectral Imagery by Convolutional Neural Networks. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 417-21.
- Herrero-Huerta M, Rodriguez-Gonzalvez P, Rainey KM, 2020. Yield prediction by machine learning from UAS-based mulit-sensor data fusion in soybean. *Plant Methods*, 16, 1, 1-16.
- Hung I, Unger D, Kulhavy D, Zhang Y, 2019. Positional precision analysis of orthomosaics derived from drone captured aerial imagery. *Drones*, 3, 2, 46.
- Inal C, Bulbul S, Bilgen B, 2018. Statistical analysis of accuracy and precision of GNSS receivers used in network RTK. *Arabian Journal of Geosciences*, 11, 10, 227.
- Inal C, Bulbul S, Bilgen BJAJoG, 2018. Statistical analysis of accuracy and precision of GNSS receivers used in network RTK. 11, 10, 227.
- Ioffe S, Szegedy CJapa, 2015. Batch normalization: Accelerating deep network training by reducing internal covariate shift.
- Kahveci M, Can N, 2017. İnsansız hava araçları: tarihçesi, tanımı, dünyada ve Türkiye'deki yasal durumu.
- Karaboğa D, 2017. Yapay Zeka Optimizasyon Algoritmaları, Nobel Akademi Yayıncılık, p.
- Karl JW, Yelich JV, Ellison MJ, Lauritzen D, 2020. Estimates of willow (*Salix* spp.) canopy volume using unmanned aerial systems. *Rangeland Ecol Manag.*
- Khan S, Naseem I, Malik MA, Togneri R, Bennamoun M, 2018. A fractional gradient descent-based rbf neural network. *Circuits, Systems, and Signal Processing*, 37, 12, 5311-32.
- Khan S, Naseem I, Malik MA, Togneri R, Bennamoun MJC, Systems,, Processing S, 2018. A fractional gradient descent-based rbf neural network. 37, 12, 5311-32.
- Koksal N, Jalalmaab M, Fidan B, 2019. Adaptive linear quadratic attitude tracking control of a quadrotor UAV based on IMU sensor data fusion. *Sensors-Basel*, 19, 1, 46.
- Kolláth Z, Cool A, Jechow A, Kolláth K, Száz D, Tong KP, 2020. Introducing the Dark Sky Unit for multi-spectral measurement of the night sky quality with commercial digital cameras. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 107162.
- Kolláth Z, Cool A, Jechow A, Kolláth K, Száz D, Tong KPJoQS, Transfer R, 2020. Introducing the Dark Sky Unit for multi-spectral measurement of the night sky quality with commercial digital cameras. 107162.
- Komarkova J, Cermakova I, Sedlak P, Jech J, 2019. Spectral Enhancement of Imagery for Small Inland Water Bodies Monitoring: Utilization of UAV-Based Data. *Journal of Information Systems Engineering and Management*, 4, 4, em0102.

- Konar M, 2019. GAO Algoritma tabanlı YSA modeliyle İHA motorunun performansının ve uçuş süresinin maksimizasyonu. *Avrupa Bilim ve Teknoloji Dergisi*, 15, 360-7.
- Krause S, Hartmann F, Mund J-P. UAV workflow optimization for the acquisition of high-quality photogrammetric point clouds in forestry. *GI-Forum*, 72-84.
- Kubat C, 2013. MATLAB: yapay zekâ ve mühendislik uygulamaları, Pusula Yayıncılık, p.
- Levenberg KJQoam, 1944. A method for the solution of certain non-linear problems in least squares. 2, 2, 164-8.
- Lichti DD, Jarron D, Shahbazi M, Helmholz P, Radovanovic R, 2019. Investigation into the behaviour and modelling of chromatic aberrations in non-metric digital cameras. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 99-106.
- Linder W, 2009. Digital photogrammetry, Springer, p.
- Macharet DG, Campos MF, 2018. A survey on routing problems and robotic systems. *Robotica*, 36, 12, 1781-803.
- Makineci H, Karabörk H, 2016. Evaluation Digital Elevation Model Generated by Synthetic Aperture Radar Data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 1.
- Makineci HB, 2016. İnsansız Hava Araçları Lidar Etkileşimi. *Geomatik*, 1, 1, 19-23.
- Makineci HB, 2016. Sentinel-1A radar uydu görüntülerinden elde edilen sayısal yükseklik modelinin kalite değerlendirmesi [Evaluation of quality of digital elevation model obtained from sentinel 1A radar satellite images], Selçuk Üniversitesi / Fen Bilimleri Enstitüsü / Harita Mühendisliği Anabilim
- Manconi A, Ziegler M, Blöchliger T, Wolter A, 2019. optimization of unmanned aerial vehicles flight planning in steep terrains. *Int J Remote Sens*, 40, 7, 2483-92.
- Manconi A, Ziegler M, Blöchliger T, Wolter AJIJoRS, 2019. optimization of unmanned aerial vehicles flight planning in steep terrains. 40, 7, 2483-92.
- Marquardt DWJJotsfI, Mathematics A, 1963. An algorithm for least-squares estimation of nonlinear parameters. 11, 2, 431-41.
- Marques O, 2011. Practical image and video processing using MATLAB, John Wiley & Sons, p.
- Martin RA, Rojas I, Franke K, Hedengren JDJRS, 2016. Evolutionary view planning for optimized uav terrain modeling in a simulated environment. 8, 1, 26.
- Maxim A, Lerke O, Prado M, Dörstelmann M, Menges A, Schwieger V, 2017. UAV Guidance with Robotic Total Station for Architectural Fabrication Processes. *Unmanned Aerial Vehicles*; Wißner-Verlag: Augsburg, Germany, 145-61.
- May R, Dandy G, Maier HJAnn-ma, applications b, 2011. Review of input variable selection methods for artificial neural networks. 10, 16004.
- Mercier Q, Poirion F, Désidéri J-A, 2018. A stochastic multiple gradient descent algorithm. *European Journal of Operational Research*, 271, 3, 808-17.
- Mercier Q, Poirion F, Désidéri J-AJEJoOR, 2018. A stochastic multiple gradient descent algorithm. 271, 3, 808-17.
- Morgenthal G, Hallermann N, Kersten J, Taraben J, Debus P, Helmrich M, Rodehorst V, 2019. Framework for automated UAS-based structural condition assessment of bridges. *Automat Constr*, 97, 77-95.
- Nex F, Duarte D, Steenbeek A, Kerle N, 2019. Towards real-time building damage mapping with low-cost UAV solutions. *Remote Sens-Basel*, 11, 3, 287.
- Okkan U, Serbeş ZA, Gedik NJDMD, 2018. MATLAB ile Levenberg-Marquardt algoritması tabanlı YSA uygulaması: Aylık yağış-akış modellemesi. 9, 1, 351-62.


- Özemir I, Uzar M, 2016. İHA İle Fotogrametrik Veri Üretimi. VI. UZAL-CBS Sempozyumu, 5-7.
- Öztürk O, Bilgilioğlu BB, Çelik MF, Bilgilioğlu SS, Raşit U, 2017. İnsansız Hava Aracı (İHA) Görüntüleri İle Ortofoto Üretiminde Yükseklik Ve Kamera Açısının Doğruluğa Etkisinin Araştırılması. *Geomatik*, 2, 3, 135-42.
- Pepe M, Fregonese L, Scaioni MJEJoRS, 2018. Planning airborne photogrammetry and remote-sensing missions with modern platforms and sensors. 51, 1, 412-36.
- Perez-Carabaza S, Besada-Portas E, Lopez-Orozco JA, Jesus M, 2018. Ant colony optimization for multi-UAV minimum time search in uncertain domains. *Appl Soft Comput*, 62, 789-806.
- Polat N, Uysal MJAJoG, 2020. An investigation of tree extraction from UAV-based photogrammetric dense point cloud. 13, 17, 1-8.
- Poley LG, McDermid GJ, 2020. A Systematic Review of the Factors Influencing the Estimation of Vegetation Aboveground Biomass Using Unmanned Aerial Systems. *Remote Sens-Basel*, 12, 7, 1052.
- Prasetia AS, Wai R-J, Wen Y-L, Wang Y-KJIA, 2019. Mission-based energy consumption prediction of multirotor UAV. 7, 33055-63.
- Radmanesh M, Kumar M, Sarim M, 2018. Grey wolf optimization based sense and avoid algorithm in a Bayesian framework for multiple UAV path planning in an uncertain environment. *Aerosp Sci Technol*, 77, 168-79.
- Radmanesh M, Kumar M, Sarim MJAS, Technology, 2018. Grey wolf optimization based sense and avoid algorithm in a Bayesian framework for multiple UAV path planning in an uncertain environment. 77, 168-79.
- Remondino F, Barazzetti L, Nex F, Scaioni M, Sarazzi D, 2011. UAV photogrammetry for mapping and 3d modeling—current status and future perspectives. *International archives of the photogrammetry, remote sensing and spatial information sciences*, 38, 1, C22.
- Remondino F, Barazzetti L, Nex F, Scaioni M, Sarazzi DJlaotp, remote sensing, sciences si, 2011. UAV photogrammetry for mapping and 3d modeling—current status and future perspectives. 38, 1, C22.
- Rizo-Maestre C, González-Avilés Á, Galiano-Garrigós A, Andújar-Montoya MD, Puchol-García JA, 2020. UAV BIM: Incorporation of Photogrammetric Techniques in Architectural Projects with Building Information Modeling Versus Classical Work Processes+. *Remote Sens-Basel*, 12, 14, 2329.
- Rojas IY, 2014. Optimized Photogrammetric Network Design with Flight Path Planner for UAV-based Terrain Surveillance.
- Rosnell T, Honkavaara E, Nurminen K, 2011. On geometric processing of multi-temporal image data collected by light UAV systems. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci*, 38, 1-6.
- Roth L, Hund A, Aasen HJPM, 2018. PhenoFly Planning Tool: flight planning for high-resolution optical remote sensing with unmanned areal systems. 14, 1, 116.
- Sağıroğlu Ş, Beşdok E, Erler M, 2003. Mühendislikte yapay zeka uygulamaları-1: Yapay sinir ağları, *Ufuk Kitap Kırtasiye-Yayıncılık*, p.
- Samad AM, Kamarulzaman N, Hamdani MA, Mastor TA, Hashim KA. The potential of Unmanned Aerial Vehicle (UAV) for civilian and mapping application. 2013 IEEE 3rd International Conference on System Engineering and Technology, 313-8.
- Sanz-Ablanedo E, Chandler JH, Ballesteros-Pérez P, Rodríguez-Pérez JR, 2020. Reducing systematic dome errors in digital elevation models through better UAV flight design. *Earth Surf Proc Land*.

- Sanz-Ablanedo E, Chandler JH, Ballesteros-Pérez P, Rodríguez-Pérez JRJESP, Landforms, 2020. Reducing systematic dome errors in digital elevation models through better UAV flight design.
- Schulze-Horn I, Hueren S, Scheffler P, Schiele H, 2020. Artificial Intelligence in Purchasing: Facilitating Mechanism Design-based Negotiations. *Applied Artificial Intelligence*, 34, 8, 618-42.
- Song Y, Xue H, Meng X, 2019. Evaluation method of slope stability based on the Q slope system and BQ method. *B Eng Geol Environ*, 78, 7, 4865-73.
- Şahin H, Oktay T, 2019. Başkalaşan Kanat Ucu Tasarımı ve Avantajları. *Avrupa Bilim ve Teknoloji Dergisi*, 17, 606-10.
- Takeuchi D, Nakanishi S, 2019. An artificial neural network model to estimate grain size on a river bed from UAV photographs and DEMs.
- Tan Q, Wang Z, Ong Y-S, Low KH. Evolutionary optimization-based mission planning for UAS traffic management (UTM). 2019 International Conference on Unmanned Aircraft Systems (ICUAS), 952-8.
- Tan RK, Bora ŞJMBvTD, 2017. MODELLEME VE BENZETİM ORTAMINDA PARAMETRE OPTİMİZASYONU VE KULLANILAN TEKNİKLER. 5, 3, 685-97.
- Tjahjadi ME, Agustina FD, Rokhmana CA, 2019. Assessing stability performance of non-metric camera's lens distortion model during UAV flight missions. *KnE Engineering*, 345-54-54.
- Tjahjadi ME, Agustina FD, Rokhmana CAJKE, 2019. Assessing stability performance of non-metric camera's lens distortion model during UAV flight missions. 345-54-54.
- Toraman S, 2018. Derin Öğrenme ile İnsansız Hava Aracı Görüntülerinden Yaya Tespiti. *Journal of Aviation*, 2, 2, 64-9.
- Tsai C-H, Lin Y-C, 2017. An accelerated image matching technique for UAV orthoimage registration. *Isprs J Photogramm*, 128, 130-45.
- Ulukavak M, Memduhoğlu A, Şenol Hİ, Polat N, 2020. The use of UAV and photogrammetry in digital documentation. *Mersin Photogrammetry Journal*.
- Uysal E, 2018. Sayısal fotogrametrik üretimler için yürürlükteki uluslararası doğruluk kriterlerinin incelenmesi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Uysal M, Toprak AS, Polat NJM, 2015. DEM generation with UAV Photogrammetry and accuracy analysis in Sahitler hill. 73, 539-43.
- Ünal A, Yıldız F, 2020. Göktürk-1 Uydu Görüntülerinin Pankeskinleştirme Performansının İncelenmesi. *Geomatik*, 6, 2, 148-64.
- Verheyden A, Jonckheere T, Gevaert S, 2019. Photogrammetry using UAV's, Høgskulen på Vestlandet/Western Norway University of Applied Sciences.
- Wai R-J, Prasetya AS, 2019. Adaptive neural network control and optimal path planning of UAV surveillance system with energy consumption prediction. *Ieee Access*, 7, 126137-53.
- Wai R-J, Prasetya ASJIA, 2019. Adaptive neural network control and optimal path planning of UAV surveillance system with energy consumption prediction. 7, 126137-53.
- Xiang J, Chen J, Sofia G, Tian Y, Tarolli P, 2018. Open-pit mine geomorphic changes analysis using multi-temporal UAV survey. *Environ Earth Sci*, 77, 6, 220.
- Yavuz S, Deveci M, 2012. İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-87.

- Yıldırım Ö, Susam T, Yaprak S, Delen A, Inyurt S, 2016. The availability of UAV systems for agricultural purposes. *Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi*, 33, 3, 111-20.
- Yılmaz AJKY, 2017. *Yapay Zekâ*. 373.
- Yılmaz HM, Mutluoğlu Ö, Ulvi A, Yaman A, Bilgilioğlu SSJJoG, 2018. İnsansız hava aracı ile ortofoto üretimi ve Aksaray Üniversitesi kampüsü örneği. 3, 2, 103-10.
- Yılmaz V, Güngör O, 2019. Estimating crown diameters in urban forests with Unmanned Aerial System-based photogrammetric point clouds. *Int J Remote Sens*, 40, 2, 468-505.
- Zhang C, Zhen Z, Wang D, Li M. UAV path planning method based on ant colony optimization. 2010 Chinese Control and Decision Conference, 3790-2.
- Zhang S, Zhou Y, Li Z, Pan W, 2016. Grey wolf optimizer for unmanned combat aerial vehicle path planning. *Advances in Engineering Software*, 99, 121-36.
- Zhang S, Zhou Y, Li Z, Pan WJAiES, 2016. Grey wolf optimizer for unmanned combat aerial vehicle path planning. 99, 121-36.
- Zohdi T, 2020. The Game of Drones: Rapid agent-based machine-learning models for multi-UAV path planning. *Computational Mechanics*, 65, 1, 217-28.
- Zohdi TJCM, 2020. The Game of Drones: Rapid agent-based machine-learning models for multi-UAV path planning. 65, 1, 217-28.

EKLER

EK-1 Büyük Ölçekli Harita ve Harita Bilgisi Üretim Yönetmeliği-2018 (Fotogrametrik Çalışmalar – EK 4 Şekil 13)



EK-2

Optimizasyon İçin Kullanılan Geliştirici Kodları

```

clear;
close;
clc;
% Load images.
% buildingDir = fullfile(toolboxdir('vision'), 'visiondata', 'building');
% buildingScene = imageDatastore(buildingDir); %resimleri hazır olarak
yukleme
%my_images = {'C:\Users\aykut\Desktop\airial_images\phantom3-freeway-
kfs\rgb\1458466573.680000.jpg'; 'C:\Users\aykut\Desktop\airial_images\phantom3-
freeway-kfs\rgb\1458466576.080000.jpg';
'C:\Users\aykut\Desktop\airial_images\phantom3-freeway-
kfs\rgb\1458466580.960000.jpg'; 'C:\Users\aykut\Desktop\airial_images\phantom3-
freeway-kfs\rgb\1458466587.360000.jpg'};
[file,path]=uigetfile({'*.jpg;*.bmp;*.png;*.tif'},'Choose images', 'MultiSelect',
'on');
tic;
numImages = size(file , 2);
my_images = [];
for n = 1:numImages
    s = [ [path , file{1,n}] ];
    my_images{end+1} = s;
end
% Display images to be stitched
%numImages = numel(buildingScene.Files);
%numImages = numel(my_images);
%montage(buildingScene.Files) %tüm resimleri gösterme
% montage_row = ceil(numImages/5);
% montage_clm = ceil(numImages/montage_row);
% montage(my_images, 'Size', [montage_row montage_clm]);
%----- Part 2 -----
% Read the first image from the image set.
%I = readimage(buildingScene, 1);
I = imread(my_images{1,1});
% Initialize features for I(1)
grayImage = rgb2gray(I);
points = detectFASTFeatures(grayImage);
[features, points] = extractFeatures(grayImage, points);
% Initialize all the transforms to the identity matrix. Note that the
% projective transform is used here because the building images are fairly
% close to the camera. Had the scene been captured from a further distance,
% an affine transform would suffice.
tforms(numImages) = projective2d(eye(3));
% Iterate over remaining image pairs
for n = 2:numImages
    % Store points and features for I(n-1).
    pointsPrevious = points;
    featuresPrevious = features;

```

```

% Read I(n).
%I = readimage(buildingScene, n);
I = imread(my_images{1,n});
% Detect and extract SURF features for I(n).
grayImage = rgb2gray(I);
points = detectFASTFeatures(grayImage);
[features, points] = extractFeatures(grayImage, points);
% Find correspondences between I(n) and I(n-1).
indexPairs = matchFeatures(features, featuresPrevious, 'Unique', true);
matchedPoints = points(indexPairs(:,1), :);
matchedPointsPrev = pointsPrevious(indexPairs(:,2), :);
% Estimate the transformation between I(n) and I(n-1).
tforms(n) = estimateGeometricTransform(matchedPoints,
matchedPointsPrev,...
    'projective', 'Confidence', 99.9, 'MaxNumTrials', 2000);
% Compute T(n) * T(n-1) * ... * T(1)
tforms(n).T = tforms(n).T * tforms(n-1).T;
end
%----- Part 3 -----
imageSize = size(I); % all the images are the same size
% Compute the output limits for each transform
for i = 1:numel(tforms)
    [xlim(i,:), ylim(i,:)] = outputLimits(tforms(i), [1 imageSize(2)], [1
imageSize(1)]);
end
%----- Part 4 -----
avgXLim = mean(xlim, 2);
[~, idx] = sort(avgXLim);
centerIdx = floor((numel(tforms)+1)/2);
centerImageIdx = idx(centerIdx);
%----- Part 5 -----
Tinv = invert(tforms(centerImageIdx));
for i = 1:numel(tforms)
    tforms(i).T = tforms(i).T * Tinv.T;
end
%----- Part 6 -----
for i = 1:numel(tforms)
    [xlim(i,:), ylim(i,:)] = outputLimits(tforms(i), [1 imageSize(2)], [1
imageSize(1)]);
end
% Find the minimum and maximum output limits
xMin = min([1; xlim(:)]);
xMax = max([imageSize(2); xlim(:)]);
yMin = min([1; ylim(:)]);
yMax = max([imageSize(1); ylim(:)]);
% Width and height of panorama.
width = round(xMax - xMin);
height = round(yMax - yMin);
% Initialize the "empty" panorama.

```

```

panorama = zeros([height width 3], 'like', I);
%----- Part 7 -----
blender = vision.AlphaBlender('Operation', 'Binary mask', ...
    'MaskSource', 'Input port');
% Create a 2-D spatial reference object defining the size of the panorama.
xLimits = [xMin xMax];
yLimits = [yMin yMax];
panoramaView = imref2d([height width], xLimits, yLimits);
% Create the panorama.
for i = 1:numImages
    I = imread(my_images{1,i});
    % Transform I into the panorama.
    warpedImage = imwarp(I, tforms(i), 'OutputView', panoramaView);
    % Generate a binary mask.
    mask = imwarp(true(size(I,1),size(I,2)), tforms(i), 'OutputView',
panoramaView);
    % Overlay the warpedImage onto the panorama.
    panorama = step(blender, panorama, warpedImage, mask);
end
figure
imshow(panorama)
imwrite(panorama,'RESULTFAST.JPG');
toc;

clc
clear all
load data.mat
load Train.mat
load Test.mat
%% 4 lü değişken için YSA tasarımı ve sonuçları
XTrain=transpose(Train(:,1:4));
YTrain=transpose(Train(:,5:6));
XTest=transpose(Test(:,1:4));
YTest=transpose(Test(:,5:6));
%ysa yapısının ve parametrelerinin ayarlanması
[net]=newff(XTrain,YTrain,[7 2],{'logsig','purelin'},'traingdx');
net.trainParam.epochs=3000;
net.trainParam.lr=2;
net.trainParam.mc=0.5;
net.trainParam.max_fail=1000;
%ysanın eğitilmesi
[net,tr]=train(net,XTrain,YTrain);
%test verilerine göre ağın ürettiği çıkışın elde edilmesi
[cikistest]=sim(net,XTest);
cikistest=round(cikistest);
L=length(XTest);
hata=0;
%test verilerine göre doğruluk oranının hesaplanması
for i=1:L

```

```

        ucus_hata_degeri(i,1)=abs(YTest(1,i)-cikistest(1,i))/YTest(1,i);
        pil_hata_degeri(i,1)=abs(YTest(2,i)-cikistest(2,i))/YTest(2,i);

    end
    figure;
    plotregression(YTest,cikistest,'Regression')
    %% 3 lü deęişken için YSA tasarımı ve sonuçları (İHA Tipi dıřarıda)
    XTrain_iha=transpose(Train(:,2:4));
    YTrain=transpose(Train(:,5:6));
    XTest_iha=transpose(Test(:,2:4));
    YTest=transpose(Test(:,5:6));
    %ysa yapısının ve parametrelerinin ayarlanması
    [net_iha]=newff(XTrain_iha,YTrain,[7 2],{'logsig','purelin'},'traingdx');
    net_iha.trainParam.epochs=3000;
    net_iha.trainParam.lr=2;
    net_iha.trainParam.mc=0.5;
    net_iha.trainParam.max_fail=1000;
    %ysanın eęitilmesi
    [net_iha,tr_iha]=train(net_iha,XTrain_iha,YTrain);
    %test verilerine göre aęın ürettięi çıkışın elde edilmesi
    [cikistest_iha]=sim(net_iha,XTest_iha);
    cikistest_iha=round(cikistest_iha);
    L=length(XTest_iha);
    hata=0;
    %test verilerine göre doęruluk oranının hesaplanması
    for i=1:L
        iha_ucus_hata_degeri(i,1)=abs(YTest(1,i)-cikistest_iha(1,i))/YTest(1,i);
        iha_pil_hata_degeri(i,1)=abs(YTest(2,i)-cikistest_iha(2,i))/YTest(2,i);

    end
    figure;
    plotregression(YTest,cikistest_iha,'Regression')
    %% 3 lü deęişken için YSA tasarımı ve sonuçları (YÖA Tipi dıřarıda)
    XTrain_yoa=[transpose(Train(:,1)); transpose(Train(:,3:4))];
    YTrain=transpose(Train(:,5:6));
    XTest_yoa=[transpose(Test(:,1)); transpose(Test(:,3:4))];
    YTest=transpose(Test(:,5:6));
    %ysa yapısının ve parametrelerinin ayarlanması
    [net_yoa]=newff(XTrain_yoa,YTrain,[7 2],{'logsig','purelin'},'traingdx');
    net_yoa.trainParam.epochs=3000;
    net_yoa.trainParam.lr=2;
    net_yoa.trainParam.mc=0.5;
    net_yoa.trainParam.max_fail=1000;
    %ysanın eęitilmesi
    [net_yoa,tr_yoa]=train(net_yoa,XTrain_yoa,YTrain);
    %test verilerine göre aęın ürettięi çıkışın elde edilmesi
    [cikistest_yoa]=sim(net_yoa,XTest_yoa);
    cikistest_yoa=round(cikistest_yoa);
    L=length(XTest_yoa);
    hata=0;

```

```

%test verilerine göre doğruluk oranının hesaplanması
for i=1:L
    yoa_ucus_hata_degeri(i,1)=abs(YTest(1,i)-cikistest_yoa(1,i))/YTest(1,i);
    yoa_pil_hata_degeri(i,1)=abs(YTest(2,i)-cikistest_yoa(2,i))/YTest(2,i);
end
figure;
plotregression(YTest,cikistest_yoa,'Regression')
%% 3 lü değişken için YSA tasarımı ve sonuçları (Bindirme oranı dışarıda)
XTrain_bo=[transpose(Train(:,1:2)); transpose(Train(:,4))];
YTrain=transpose(Train(:,5:6));
XTest_bo=[transpose(Test(:,1:2)); transpose(Test(:,4))];
YTest=transpose(Test(:,5:6));
%ysa yapısının ve parametrelerinin ayarlanması
[net_bo]=newff(XTrain_bo,YTrain,[7 2],{'logsig','purelin'},'traingdx');
net_bo.trainParam.epochs=3000;
net_bo.trainParam.lr=2;
net_bo.trainParam.mc=0.5;
net_bo.trainParam.max_fail=1000;
%ysanın eğitilmesi
[net_bo,tr_bo]=train(net_bo,XTrain_bo,YTrain);
%test verilerine göre ağın ürettiği çıkışın elde edilmesi
[cikistest_bo]=sim(net_bo,XTest_bo);
cikistest_bo=round(cikistest_bo);
L=length(XTest_bo);
hata=0;
%test verilerine göre doğruluk oranının hesaplanması
for i=1:L
    bo_ucus_hata_degeri(i,1)=abs(YTest(1,i)-cikistest_bo(1,i))/YTest(1,i);
    bo_pil_hata_degeri(i,1)=abs(YTest(2,i)-cikistest_bo(2,i))/YTest(2,i);
end
figure;
plotregression(YTest,cikistest_bo,'Regression')
%% 3 lü değişken için YSA tasarımı ve sonuçları (Atmosferik Koşullar dışarıda)
XTrain_ak=transpose(Train(:,1:3));
YTrain=transpose(Train(:,5:6));
XTest_ak=transpose(Test(:,1:3));
YTest=transpose(Test(:,5:6));
%ysa yapısının ve parametrelerinin ayarlanması
[net_ak]=newff(XTrain_ak,YTrain,[7 2],{'logsig','purelin'},'traingdx');
net_ak.trainParam.epochs=1500;
net_ak.trainParam.lr=2;
net_ak.trainParam.mc=0.5;
net_ak.trainParam.max_fail=1000;
%ysanın eğitilmesi
[net_ak,tr_ak]=train(net_ak,XTrain_ak,YTrain);
%test verilerine göre ağın ürettiği çıkışın elde edilmesi
[cikistest_ak]=sim(net_ak,XTest_ak);
cikistest_ak=round(cikistest_ak);

```

```

L=length(XTest_ak);
hata=0;
%test verilerine göre doğruluk oranının hesaplanması
for i=1:L
    ak_ucus_hata_degeri(i,1)=abs(YTest(1,i)-cikistest_ak(1,i))/YTest(1,i);
    ak_pil_hata_degeri(i,1)=abs(YTest(2,i)-cikistest_ak(2,i))/YTest(2,i);
end
figure;
plotregression(YTest,cikistest_ak,'Regression')
ortalama_ucus_dogruluk=(1-mean(ucus_hata_degeri))*100;
fprintf('Ortalama ucuş süresi doğruluk oranı=%f\n', ortalama_ucus_dogruluk);
ortalama_pil_dogruluk=(1-mean(pil_hata_degeri))*100;
fprintf('Ortalama pil süresi doğruluk oranı=%f\n', ortalama_pil_dogruluk);
iha_ortalama_ucus_dogruluk=(1-mean(iha_ucus_hata_degeri))*100;
fprintf('İHA olmadan ortalama ucuş süresi doğruluk oranı=%f\n',
iha_ortalama_ucus_dogruluk);
iha_ortalama_pil_dogruluk=(1-mean(iha_pil_hata_degeri))*100;
fprintf('İHA olmadan ortalama pil süresi doğruluk oranı=%f\n',
iha_ortalama_pil_dogruluk);
yoa_ortalama_ucus_dogruluk=(1-mean(yoa_ucus_hata_degeri))*100;
fprintf('YÖA olmadan ortalama ucuş süresi doğruluk oranı=%f\n',
yoa_ortalama_ucus_dogruluk);
yoa_ortalama_pil_dogruluk=(1-mean(yoa_pil_hata_degeri))*100;
fprintf('YÖA olmadan ortalama pil süresi doğruluk oranı=%f\n',
yoa_ortalama_pil_dogruluk);
bo_ortalama_ucus_dogruluk=(1-mean(bo_ucus_hata_degeri))*100;
fprintf('BO olmadan ortalama ucuş süresi doğruluk oranı=%f\n',
bo_ortalama_ucus_dogruluk);
bo_ortalama_pil_dogruluk=(1-mean(bo_pil_hata_degeri))*100;
fprintf('BO olmadan ortalama pil süresi doğruluk oranı=%f\n',
bo_ortalama_pil_dogruluk);
ak_ortalama_ucus_dogruluk=(1-mean(ak_ucus_hata_degeri))*100;
fprintf('AK olmadan ortalama ucuş süresi doğruluk oranı=%f\n',
ak_ortalama_ucus_dogruluk);
ak_ortalama_pil_dogruluk=(1-mean(ak_pil_hata_degeri))*100;
fprintf('AK olmadan ortalama pil süresi doğruluk oranı=%f\n',
ak_ortalama_pil_dogruluk);
figure
hold on
plot(tr_iha.epoch,tr_iha.perf , '--','Linewidth',1);
plot(tr_yoa.epoch,tr_yoa.perf , '--','Linewidth',1);
plot(tr_bo.epoch,tr_bo.perf , '--','Linewidth',1);
plot(tr_ak.epoch,tr_ak.perf , '--','Linewidth',1);
hold off
grid on
xlabel('iterasyon');
ylabel('kayıp');
title('Kayıp Grafiği')
function varargout = deneme(varargin)
% DENEME MATLAB code for deneme.fig

```

```

% DENEME, by itself, creates a new DENEME or raises the existing
% singleton*.
%
% H = DENEME returns the handle to a new DENEME or the handle to
% the existing singleton*.
%
% DENEME('CALLBACK',hObject,eventData,handles,...) calls the local
% function named CALLBACK in DENEME.M with the given input
arguments.
%
% DENEME('Property','Value',...) creates a new DENEME or raises the
% existing singleton*. Starting from the left, property value pairs are
% applied to the GUI before deneme_OpeningFcn gets called. An
% unrecognized property name or invalid value makes property application
% stop. All inputs are passed to deneme_OpeningFcn via varargin.
%
% *See GUI Options on GUIDE's Tools menu. Choose "GUI allows only one
% instance to run (singleton)".
%
% See also: GUIDE, GUIDATA, GUIHANDLES
% Edit the above text to modify the response to help deneme
% Last Modified by GUIDE v2.5 25-Jun-2020 12:42:30
% Begin initialization code - DO NOT EDIT
gui_Singleton = 1;
gui_State = struct('gui_Name',    mfilename, ...
    'gui_Singleton', gui_Singleton, ...
    'gui_OpeningFcn', @deneme_OpeningFcn, ...
    'gui_OutputFcn', @deneme_OutputFcn, ...
    'gui_LayoutFcn', [] , ...
    'gui_Callback', []);
if nargin && ischar(varargin(1))
    gui_State.gui_Callback = str2func(varargin(1));
end
if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
% End initialization code - DO NOT EDIT
clear all
%% 4 lü de?i?ken için YSA tasar?m? ve sonuçlar?
% --- Executes just before deneme is made visible.
function deneme_OpeningFcn(hObject, eventdata, handles, varargin)
% This function has no output args, see OutputFcn.
% hObject    handle to figure
% eventdata  reserved - to be defined in a future version of MATLAB
% handles     structure with handles and user data (see GUIDATA)
% varargin    command line arguments to deneme (see VARARGIN)
% Choose default command line output for deneme
handles.output = hObject;

```

```

% Update handles structure
guidata(hObject, handles);
% UIWAIT makes deneme wait for user response (see UIRESUME)
% uiwait(handles.figure1);
% --- Outputs from this function are returned to the command line.
function varargout = deneme_OutputFcn(hObject, eventdata, handles)
% varargout cell array for returning output args (see VARARGOUT);
% hObject handle to figure
% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
% Get default command line output from handles structure
varargout{1} = handles.output;
% --- Executes on selection change in popupmenu1.
function popupmenu1_Callback(hObject, eventdata, handles)
% hObject handle to popupmenu1 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
deger=get(hObject,'Value');%yaz?lan sifre çekiliyor;
if deger==get(hObject,'Max')
    iha_tipi=0
else
    iha_tipi=1
end
% handles structure with handles and user data (see GUIDATA)

% Hints: contents = cellstr(get(hObject,'String')) returns popupmenu1 contents as
cell array
% contents{get(hObject,'Value')} returns selected item from popupmenu1
% --- Executes during object creation, after setting all properties.
function popupmenu1_CreateFcn(hObject, eventdata, handles)
% hObject handle to popupmenu1 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles empty - handles not created until after all CreateFcns called
% Hint: popupmenu controls usually have a white background on Windows.
% See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit1_Callback(hObject, eventdata, handles)
% hObject handle to edit1 (see GCBO)
% eventdata reserved - to be defined in a future version of MATLAB
% handles structure with handles and user data (see GUIDATA)
global yoa
yoa=str2double(get(hObject,'String'));
yoa
% Hints: get(hObject,'String') returns contents of edit1 as text
% str2double(get(hObject,'String')) returns contents of edit1 as a double

```

```

% --- Executes during object creation, after setting all properties.
function edit1_CreateFcn(hObject, eventdata, handles)
% hObject    handle to edit1 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called
% Hint: edit controls usually have a white background on Windows.
%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
% --- Executes on selection change in popupmenu2.
function popupmenu2_Callback(hObject, eventdata, handles)
% hObject    handle to popupmenu2 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
global deger_BO
deger_BO=get(hObject,'Value');%yaz?lan sifre çekiliyor;
deger_BO
% Hints: contents = cellstr(get(hObject,'String')) returns popupmenu2 contents as
cell array
%     contents{get(hObject,'Value')} returns selected item from popupmenu2
% --- Executes during object creation, after setting all properties.
function popupmenu2_CreateFcn(hObject, eventdata, handles)
% hObject    handle to popupmenu2 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called
% Hint: popupmenu controls usually have a white background on Windows.
%         See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit2_Callback(hObject, eventdata, handles)
% hObject    handle to edit2 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
load net.mat
deger=get(handles.popupmenu1,'Value');%yaz?lan sifre çekiliyor;
if deger==get(handles.popupmenu1,'Max')
    iha_tipi=0
else
    iha_tipi=1
end
yoa=str2double(get(handles.edit1,'String'));
yoa
deger_BO=get(handles.edit2,'Value');%yaz?lan sifre çekiliyor;
deger_BO
At_kos=str2double(get(hObject,'String'));
At_kos

```

```

XTest=[iha_tipi;yoa;deger_BO;At_kos]
[cikistest_iha]=sim(net,XTest)
set(handles.edit3,'String',num2str(cikistest_iha(1,1)));
set(handles.edit4,'String',num2str(cikistest_iha(2,1)));
% Hints: get(hObject,'String') returns contents of edit2 as text
%      str2double(get(hObject,'String')) returns contents of edit2 as a double
% --- Executes during object creation, after setting all properties.
function edit2_CreateFcn(hObject, eventdata, handles)
% hObject    handle to edit2 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called
% Hint: edit controls usually have a white background on Windows.
%      See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit3_Callback(hObject, eventdata, handles)
% hObject    handle to edit3 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% Hints: get(hObject,'String') returns contents of edit3 as text
%      str2double(get(hObject,'String')) returns contents of edit3 as a double
% --- Executes during object creation, after setting all properties.
function edit3_CreateFcn(hObject, eventdata, handles)
% hObject    handle to edit3 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called
% Hint: edit controls usually have a white background on Windows.
%      See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor','white');
end
function edit4_Callback(hObject, eventdata, handles)
% hObject    handle to edit4 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    structure with handles and user data (see GUIDATA)
% Hints: get(hObject,'String') returns contents of edit4 as text
%      str2double(get(hObject,'String')) returns contents of edit4 as a double
% --- Executes during object creation, after setting all properties.
function edit4_CreateFcn(hObject, eventdata, handles)
% hObject    handle to edit4 (see GCBO)
% eventdata  reserved - to be defined in a future version of MATLAB
% handles    empty - handles not created until after all CreateFcns called
% Hint: edit controls usually have a white background on Windows.
%      See ISPC and COMPUTER.
if ispc && isequal(get(hObject,'BackgroundColor'),
get(0,'defaultUicontrolBackgroundColor'))

```

```
        set(hObject,'BackgroundColor','white');
    end
    % --- Executes during object creation, after setting all properties.
    function axes1_CreateFcn(hObject, eventdata, handles)
    % hObject    handle to axes1 (see GCBO)
    % eventdata  reserved - to be defined in a future version of MATLAB
    % handles    empty - handles not created until after all CreateFcns called
    imshow('ysa.png')
    % Hint: place code in OpeningFcn to populate axes1
```



EK-3 Örnek Dengeleme Raporu**kampüs vadi**

Survey Data




Fig. 1. Camera locations and image overlap.

Number of images:	154	Camera stations:	154
Flying altitude:	91.5 m	Tie points:	100,490
Ground resolution:	2.46 cm/pix	Projections:	729,299
Coverage area:	0.106 km ²	Reprojection error:	0.673 pix

Camera Model	Resolution	Focal Length	Pixel Size	Precalibrated
FC6310 (8.8mm)	5472 x 3648	8.8 mm	2.41 x 2.41 μ m	No

Table 1. Cameras.

Camera Calibration




Fig. 2. Image residuals for FC6310 (8.8mm).

FC6310 (8.8mm)

154 images

Type	Resolution	Focal Length	Pixel Size
Frame	5472 x 3648	8.8 mm	2.41 x 2.41 μm

	Value	Error	F	Cx	Cy	B1	B2	K1	K2	K3	K4	P1	P2
F	3723.78	1.3	1.00	0.02	0.76	-0.08	0.12	0.54	-0.43	0.54	-0.60	-0.05	0.41
Cx	-7.6463	0.033		1.00	0.01	-0.21	-0.11	0.05	-0.01	0.01	-0.01	0.48	0.03
Cy	16.5499	0.044			1.00	0.01	-0.03	0.42	-0.34	0.42	-0.46	-0.05	0.55
B1	-0.317854	0.0037				1.00	-0.00	-0.03	0.01	-0.02	0.03	-0.06	-0.03
B2	0.880916	0.0035					1.00	0.06	-0.05	0.07	-0.07	0.00	0.00
K1	0.0223176	7e-005						1.00	-0.86	0.86	-0.84	0.00	0.35
K2	-0.0853359	0.00029							1.00	-0.98	0.95	0.01	-0.18
K3	0.156809	0.00064								1.00	-0.99	-0.02	0.23
K4	-0.0963039	0.00047									1.00	0.03	-0.25
P1	-0.000179665	1.7e-006										1.00	-0.01
P2	0.000609438	1.5e-006											1.00

Table 2. Calibration coefficients and correlation matrix.

Camera Locations




Fig. 3. Camera locations and error estimates.
 Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.
 Estimated camera locations are marked with a black dot.

X error (m)	Y error (m)	Z error (m)	XY error (m)	Total error (m)
1.60389	3.16621	36.5243	3.54928	36.6963

Table 3. Average camera location error.
 X - Easting, Y - Northing, Z - Altitude.

Ground Control Points




Fig. 4. GCP locations and error estimates.

Z error is represented by ellipse color. X,Y errors are represented by ellipse shape.

Estimated GCP locations are marked with a dot or crossing.

Count	X error (cm)	Y error (cm)	Z error (cm)	XY error (cm)	Total (cm)
4	3.83818	3.54852	4.2432	5.2272	6.73264

Table 4. Control points RMSE.

X - Easting, Y - Northing, Z - Altitude.

Count	X error (cm)	Y error (cm)	Z error (cm)	XY error (cm)	Total (cm)
4	5.36097	1.58074	3.17794	5.58916	6.42947

Table 5. Check points RMSE.

X - Easting, Y - Northing, Z - Altitude.

Label	X error (cm)	Y error (cm)	Z error (cm)	Total (cm)	Image (pix)
P.1	-3.46536	-2.9545	-6.27651	7.7545	0.025 (7)
P.7	4.48728	-1.58398	-2.24177	5.26024	0.018 (7)
P.8	4.60046	3.21704	3.28034	6.50186	0.023 (7)
P.10	-2.37024	5.36475	4.10345	7.15799	0.018 (7)
Total	3.83818	3.54852	4.2432	6.73264	0.021

Table 6. Control points.
X - Easting, Y - Northing, Z - Altitude.

Label	X error (cm)	Y error (cm)	Z error (cm)	Total (cm)	Image (pix)
P.2	-9.0015	-0.137571	-2.81318	9.43186	0.033 (7)
P.3	1.02906	-1.41097	1.64941	2.40216	0.014 (7)
P.5	3.04982	-0.852966	1.77009	3.62797	0.023 (7)
P.9	4.85516	-2.69399	5.16038	7.58022	0.023 (8)
Total	5.36097	1.58074	3.17794	6.42947	0.024

Table 7. Check points.
X - Easting, Y - Northing, Z - Altitude.

Digital Elevation Model




Fig. 5. Reconstructed digital elevation model.

Resolution: 8.97 cm/pix
Point density: 124 points/m²

Processing Parameters

General	
Cameras	154
Aligned cameras	154
Markers	8
Shapes	
Coordinate system	TUREF / TM33 (EPSG::5255)
Coordinate system	TUREF / TM27 (EPSG::5253)
Rotation angles	Yaw, Pitch, Roll
Point Cloud	
Points	100,490 of 109,794
RMS reprojection error	0.135846 (0.673367 pix)
Max reprojection error	0.486304 (21.388 pix)
Mean key point size	4.68903 pix
Point colors	3 bands, uint8
Key points	No
Average tie point multiplicity	7.60926
Alignment parameters	
Accuracy	High
Generic preselection	Yes
Reference preselection	Yes
Key point limit	40,000
Tie point limit	5,000
Adaptive camera model fitting	Yes
Matching time	3 minutes 21 seconds
Alignment time	50 seconds
Optimization parameters	
Parameters	f, b1, b2, cx, cy, k1-k4, p1-p4
Adaptive camera model fitting	Yes
Optimization time	9 seconds
DEM	
Size	6,696 x 5,389
Coordinate system	TUREF / TM33 (EPSG::5255)
Reconstruction parameters	
Source data	Dense cloud
Interpolation	Enabled
Processing time	27 seconds
Orthomosaic	
Size	8,841 x 6,648
Coordinate system	TUREF / TM33 (EPSG::5255)
Colors	3 bands, uint8
Reconstruction parameters	
Blending mode	Mosaic
Surface	DEM
Enable hole filling	Yes
Processing time	49 seconds
Software	
Version	1.5.0
Platform	Windows 64

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hasan Bilgehan MAKİNECİ
Uyruğu : T.C.
Doğum Yeri ve Tarihi : KONYA / 16.02.1988
Telefon : 0332 205 1640
Faks : -
E-Posta : hbmakineci@ktun.edu.tr / bilgehanmakineci@gmail.com

EĞİTİM

Derece	Adı	Bitirme Yılı
Lise	: Antalya Anadolu Lisesi	2006
Üniversite	: Yıldız Teknik Üniversitesi	2012
Yüksek Lisans	: Selçuk Üniversitesi	2016
Doktora	: Konya Teknik Üniversitesi	2020

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2012-2013	FMC Harita	Harita Mühendisi
2013-2014	Uluova İnşaat	Harita Mühendisi
2014-	Konya Teknik Üniversitesi	Araştırma Görevlisi

UZMANLIK ALANI

- Fotogrametri; Uzaktan Algılama; SAR; İHA; Optimizasyon; Yapay Zeka

YABANCI DİLLER

- İngilizce

YAYINLAR

- “Accuracy Assessment of DEMs Derived from Multiple SAR Data Using the InSAR Technique” *Arabian Journal for Science and Engineering*, Kabul edildi, basım aşamasında, 2020

(Yüksek Lisans Tezinden Yapılmıştır)

H Karabörk, HB Makineci, O Orhan, P Karakuş

- “Comparison of Digital Elevation Models Produced with Photogrammetric Usage of UAV by Geodetic Techniques” *Türkiye Uzaktan Algılama Dergisi*, 22, 58 – 69, 2020

(Doktora Tezinden Yapılmıştır)

HB Makineci, H Karabörk, A Durdu

- “The Performance Evaluation of Image Matching Techniques within UAV Images” *Turkish Journal of Geosciences*, 11, 8 – 14, 2020

(Doktora Tezinden Yapılmıştır)

HB Makineci, H Karabörk, A Durdu

- “Boundary constrained voxel segmentation for 3D point clouds using local geometric differences” *Expert Systems with Applications*, 157, 1 – 19, 2020

A Sağlam, HB Makineci, NA Baykan, ÖK Baykan

- “Evaluation Digital Elevation Model Generated by Synthetic Aperture Radar Data” *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 9 2016

(Yüksek Lisans Tezinden Yapılmıştır)

HB Makineci, H Karabörk

- “Sentinel-1A radar uydu görüntülerinden elde edilen sayısal yükseklik modelinin kalite değerlendirmesi” Selçuk Üniversitesi / Fen Bilimleri Enstitüsü / Harita Mühendisliği Anabilim Dalı 2016

(Yüksek Lisans Tezi)

HB Makineci