



**İNSANSIZ HAVA ARAÇLARI İÇİN KONUM  
KESTİRİMİNDE MAKİNE ÖĞRENİMİ DESTEKLİ  
SENSÖR FÜZYONU**

**Ebubekir ÜNLÜ**

**2021  
YÜKSEK LİSANS TEZİ  
MEKATRONİK MÜHENDİSLİĞİ**

**Tez Danışmanı  
Doç. Dr. Can Bülent FİDAN**

**İNSANSIZ HAVA ARAÇLARI İÇİN KONUM KESTİRİMİNDE MAKİNE  
ÖĞRENİMİ DESTEKLİ SENSÖR FÜZYONU**

**Ebubekir ÜNLÜ**

**T.C.  
Karabük Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Mekatronik Mühendisliği Anabilim Dalında  
Yüksek Lisans Tezi  
Olarak Hazırlanmıştır**

**Tez Danışmanı  
Doç. Dr. Can Bülent FİDAN**

**KARABÜK  
Temmuz 2021**

Ebubekir ÜNLÜ tarafından hazırlanan “İNSANSIZ HAVA ARAÇLARI İÇİN KONUM KESTİRİMİNDE MAKİNE ÖĞRENİMİ DESTEKLİ SENSÖR FÜZYONU” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Doç. Dr.Can Bülent FİDAN .....

Tez Danışmanı, Mekatronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Mekatronik Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 09/07/2021

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Can Bülent FİDAN (KBÜ) .....

Üye : Dr.Öğr.Üyesi Ramazan ÖZMEN (KBÜ) .....

Üye : Doç. Dr. Bektaş ÇOLAK (GTÜ)

Online

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ .....

Lisansüstü Eğitim Enstitüsü Müdürü

*“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”*

Ebubekir ÜNLÜ

## **ÖZET**

**Yüksek Lisans Tezi**

### **İNSANSIZ HAVA ARAÇLARI İÇİN KONUM KESTİRİMİNDE MAKİNE ÖĞRENİMİ DESTEKLİ SENSÖR FÜZYONU**

**Ebubekir ÜNLÜ**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Mekatronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Doç. Dr. Can Bülent FİDAN**

**Temmuz 2021, 80 sayfa**

Havacılık tarihi boyunca araçların seyrüsefer sırasında coğrafi olarak nerede buldukları, güvenlik açısından merak edilegelmiştir. Yapılan birçok mühendislik çalışmaları bu problemi çözmeye yönelik yöntemler geliştirmiş ve günümüzde ise çok küçük sensörler yardımı ile bu bilgileri kullanarak otonom seyrüseferler gerçekleştirilmektedir. Bu yöntemlerin birçoğu araç dışı bir referans noktasını baz alarak aracın yerini tespit edebilmektedir.

Son yıllarda hızla gelişen GNSS (Küresel Navigasyon Uydu Sistemleri) sayesinde araçta bulunan alıcı ile araçların konumlarının tespiti kolaylaşmıştır. Fakat çok düşük frekansta yayın yapan bu uydular çoğu zaman kesintiye uğrayabilmektedir. Ayrıca gelişmiş ülkelerin sahip olduğu bu uydu sistemlerinin kritik durumlarda devre dışı bırakılması söz konusu olduğu için dahili sensörler ile konum tahmini elzem hale gelmiştir.

Bu alıřmada insansız hava aralarının seyrüseferlerini ve görevlerini güvenli bir şekilde tamamlamaları için kritik bilgilerden olan konum bilgisinin kestirimi problemine makine öğrenimi yöntemi ile bir çözüm sunulmuřtur.

**Anahtar Sözcükler :** İnsansız hava araçları, makine öğrenimi, sensör füzyonu, konumlandırma, konum kestirimi

**Bilim Kodu** : 92906

## **ABSTRACT**

**M. Sc. Thesis**

### **MACHINE LEARNING SUPPORTED SENSOR FUSION IN POSITION ESTIMATION FOR UNMANNED AERIAL VEHICLES**

**Ebubekir ÜNLÜ**

**Karabük University  
Institute of Graduate Programs  
Department of Mechatronics Engineering**

**Thesis Advisor:**

**Doç. Dr. Can Bülent FİDAN**

**July 2021, 80 pages**

Throughout the history of aviation, the geographical location of the vehicles during navigation has been wondered in terms of safety. Many engineering studies have developed methods to solve this problem, and today, autonomous navigation is carried out using this information with the help of very small sensors. Many of these methods are able to locate the vehicle by taking an external reference point.

Thanks to the rapidly developing GNSS (Global Navigation Satellite Systems) in recent years, it has become easier to determine the location of the vehicles with the receiver in the vehicle. However, these satellites, which broadcast at very low frequencies, can often be interrupted. In addition, since these satellite systems owned by developed countries are deactivated in critical situations, position estimation with internal sensors has become essential.

In this study, a solution to the problem of estimation of position information, which is one of the critical information for unmanned aerial vehicles to complete their navigation and missions safely, is presented by machine learning method.

**Key Word** : Unmanned aerial vehicle, machine learning, sensor fusion, position, location estimation

**Science Code** : 92906



## TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Do. Dr. Can Bülent FİDAN'a sonsuz teőekkürlerimi sunarım.

Yine bu süreçte tecrübelerini benden esirgemeyen akademik camiadaki hocalarıma ve dostlarıma, hususi ile Recep KARATAŐ, Ali Tahir KARAOŐAHİN, İbrahim SAT ve Semih PAK'a teőekkürlerimi sunarım.

Sevgili aileme maddi ve manevi yardımlarını esirgemedен yanımda oldukları için tüm kalbimle teőekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ .....	xv
SİMGELER VE KISALTMALAR DİZİNİ .....	xvi
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	2
LİTERATÜR TARAMA .....	2
BÖLÜM 3 .....	5
İNSANSIZ HAVA ARAÇLARI İÇİN KONUM KESTİRİMİ.....	5
3.1. İNSANSIZ HAVA ARAÇLARININ SINIFLANDIRILMASI.....	5
3.2. AVİYONİK SİSTEMLER .....	7
3.2.1. Ataletsel Ölçüm Birimi (IMU) .....	7
3.2.1.1. İvmeölçer .....	7
3.2.1.2. Dönüölçer (Jiroskop) .....	8
3.2.1.3. Manyetometre .....	9
3.2.2. Duruş ve Yönelim Referans Sistemi (AHRS) .....	9
3.3. SEYRÜSEFER SİSTEMLERİ.....	10
3.3.1. Temel Seyrüsefer Sistemleri.....	11
3.3.2. Radyo Seyrüsefer Sistemleri .....	11
3.3.2.1. Uçaklarda Kullanılan Mevcut Radyo Seyrüsefer Sistemleri .....	13

	<b><u>Sayfa</u></b>
3.4. HESABI SEYRÜSEFER SİSTEMLERİ .....	14
3.4.1. Doppler / Yönelme Referans Sistemi .....	15
3.4.2. Hava Veri / Yönelme Sistemi .....	15
3.4.3. Ataletsel Seyrüsefer Sistemi .....	15
3.5. İNSANSIZ HAVA ARAÇLARI İÇİN DURUM BİLGİSİ .....	16
3.5.1. Koordinat Sistemleri .....	16
3.5.2. Duruş .....	17
3.5.3. Konum .....	18
BÖLÜM 4 .....	20
SENSÖR FÜZYONU .....	20
4.1. SENSÖR FÜZYONU YÖNTEMLERİ .....	20
4.2. SENSÖR FÜZYON ALGORİTMALARI .....	21
4.2.1. Kalman Filtresi .....	21
4.2.2. Tamamlayıcı Filtre .....	22
BÖLÜM 5 .....	24
MAKİNE ÖĞRENİMİ .....	24
5.1. ÖĞRENME KURALLARI .....	25
5.1.1. Hebb Öğrenme Kuralı .....	25
5.1.2. Delta Öğrenme Kuralı .....	26
5.1.3. Hopfield Öğrenme Kuralı .....	26
5.1.4. Kohonen Öğrenme Kuralı .....	26
5.2. MAKİNE ÖĞRENİMİ ALGORİTMALARI .....	26
5.2.1. Çoklu Doğrusal Regresyon .....	27
5.2.2. Polinomial Regresyon .....	29
5.3. DEĞİŞKEN SEÇME YÖNTEMLERİ .....	30
5.3.1. Olasılık Değeri (P-Value) .....	30
5.3.2. Veri Eleme Yöntemleri .....	31
5.3.2.1. Bütün Değişkenleri Dahil Etme Yöntemi .....	31
5.3.2.2. Geriye Doğru Eleme Yöntemi .....	32
5.3.2.2. İleriye Seçim Yöntemi .....	32

	<b><u>Sayfa</u></b>
5.3.2.3. Çift Yönlü Eleme .....	33
5.4. DETERMİNASYON KATSAYISI (R-KARE).....	33
BÖLÜM 6 .....	35
SENSÖR FÜZYONU VE MAKİNE ÖĞRENİMİ .....	35
6.1. KONUM KESTİRİMİ İÇİN SENSÖR FÜZYONU MODELİ .....	35
6.2. KONUM KESTİRİMİ İÇİN MAKİNE ÖĞRENİMİ MODELİ .....	37
6.3. DEĞERLENDİRME .....	38
BÖLÜM 7 .....	39
MATERYAL VE METOT .....	39
7.1. SİMÜLASYON ORTAMI .....	39
7.1.1. Robot İşletim Sistemi (ROS).....	40
7.1.2. MAVLink .....	40
7.1.3. PX4 Firmware.....	41
7.1.4. Gazebo .....	41
7.1.5. QGroundControl .....	42
7.1.6. Python Drone-kit Kütüphanesi .....	42
7.2. VERİ YAPISI.....	43
7.3. VERİ SETİ .....	44
7.4. VERİ İŞLEME VE DENEY ORTAMI.....	46
7.4.1. Spyder-IDE .....	46
7.4.2. Python Scikit-learn Kütüphanesi .....	47
BÖLÜM 8 .....	48
MAKİNE ÖĞRENİMİ DESTEKLİ KONUM KESTİRİMİ .....	48
8.1. VERİ SETİ OPTİMİZASYONU .....	48
8.1.1. Ham Veri Setinin Algoritma Performanslarının Değerlendirilmesi.....	49
8.1.2. Veri Örneklem Adeti Optimizasyonu .....	51
8.1.2.1.ÇDR İçin Veri Seti Örneklem Adeti Optimizasyonu Analizi.....	52
8.1.2.2. PR Veri Seti Örneklem Adeti Optimizasyonu Analizi .....	55
8.1.2.3. Optimizasyon Sonuç Değerlendirmesi .....	58

	<b><u>Sayfa</u></b>
8.1.3. Bağımsız Değişken Optimizasyonu.....	59
8.2. KONUM KESTİRİM DENEYİ .....	61
8.2.1. Çoklu Doğrusal Regresyon İle Konum Kestirimi .....	62
8.2.2. Polinomial Regresyon İle Konum Kestirimi .....	65
8.2.3. Konum Kestirim Değerlendirmesi.....	67
BÖLÜM 9 .....	70
SONUÇLAR .....	70
KAYNAKLAR .....	72
ÖZGEÇMİŞ .....	80

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 3.1 Döner kanatlı insansız hava aracı örneği (helikopter), Baykar Malazgirt. ...	6
Şekil 3.2 Sabit kanatlı hava aracı örneği, Bayraktar TB2. ....	6
Şekil 3.3 Duruş ve Euler açıları [16]. ....	18
Şekil 3.4 Koordinat Sistemleri ve Konum [16]. ....	19
Şekil 4.1 JDL modeli akış diyagramı. ....	21
Şekil 4.2 Kalman filtresi çalışma modeli [25]. ....	22
Şekil 4.3 Tamamlayıcı filtre blok diyagram gösterimi. ....	23
Şekil 5.1 Basit doğrusal regresyon modeli[41]. ....	28
Şekil 5.2 Üç boyutlu bir çoklu doğrusal regresyon modeli[41]. ....	28
Şekil 5.3 Basit bir Polinomial regresyon modeli ....	29
Şekil 6.1 ASS sensör füzyon modeli veri tahmin süreci. ....	35
Şekil 6.2 ASS sensör füzyon modeli, Kalman filtresi algoritma süreci. ....	36
Şekil 6.3 Makine öğrenimi modelinin oluşturulma süreci. ....	37
Şekil 6.4 Makine öğrenimi modeli ile konum tahmin döngüsü. ....	38
Şekil 7.1 Simülasyon organizasyonu ve haberleşme şeması. ....	40
Şekil 7.2 Gazebo kullanıcı arayüzü. ....	41
Şekil 7.3 QGroundControl kullanıcı arayüzü. ....	42
Şekil 7.4 Türkiye haritası üzerinde verileri alınan uçuşlara ait konumlar. ....	44
Şekil 7.5 İzmir uçuş seyrüsefer güzergahının simülasyon ekran görüntüsü. ....	44
Şekil 7.6 Spyder-IDE görünümü [55]. ....	47
Şekil 7.7 Scikit-Learn ve Python logoları. ....	47
Şekil 8.1 a) ÇDR enlem boylam tahmin grafiği. b) ÇDR hata grafiği. ....	51
Şekil 8.2 (a) Doğrusal uçuş güzergahı. (b) Geometrik uçuş güzergahı. ....	52
Şekil 8.3 Doğrusal uçuş güzergâhı ÇDR konum tahmin sonuçları. ....	53
Şekil 8.4 Geometrik uçuş güzergâhı ÇDR konum tahmin sonuçları. ....	54
Şekil 8.5 (a) ÇDR, doğrusal uçuş güzergâh tahmin sonuçları. (b) ÇDR, geometrik uçuş güzergâh tahmin sonuçları. ....	55
Şekil 8.6 Doğrusal uçuş güzergâhı PR konum tahmin sonuçları. ....	56

**Sayfa**

Şekil 8.7 Geometrik uçuş güzergâhı PR konum tahmin sonuçları. ....	56
Şekil 8.8 PR, doğrusal uçuş güzergâh tahmin sonuçları. (b) PR, geometrik uçuş güzergâh tahmin sonuçları.....	57
Şekil 8.9 ÇDR ve PR konum tahmin deneyi sonuçları. ....	59
Şekil 8.10 ÇDR ve PR konum tahmin deneyi sonuçları. ....	61
Şekil 8.11 KBÜ kampüsü üzerindeki uçuş güzergahı.....	62
Şekil 8.12 ÇDR konum kestirim sonuçları. ....	64
Şekil 8.13 ÇDR maksimum $R^2$ ve minimum ortalama hata uçuş güzergahları. ....	64
Şekil 8.14 PR konum kestirim sonuçları.....	66
Şekil 8.15 PR maksimum $R^2$ ve minimum ortalama hata uçuş güzergahları.....	66
Şekil 8.16 Deney uçuşuna ait ÇDR ve PR algoritmalarının performans grafikleri. ..	68
Şekil 8.17 ÇDR ve PR'e ait konum kestirimi uçuş güzergahları. ....	68
Şekil 8.18 ÇDR ve PR'e ait enlem, boylam kestirim grafikleri.....	69

## ÇİZELGELER DİZİNİ

	<b><u>Sayfa</u></b>
Çizelge 7.1 Veri seti değişkenleri ve açıklamaları.....	43
Çizelge 7.2 Veri seti örneklemi. ....	43
Çizelge 7.3 Yapılan uçuşların detaylı bilgileri.....	45
Çizelge 8.1 Ham veri setinin performans değerlendirmesi.....	49
Çizelge 8.2 Örneklem adeti optimizasyonu performans değerleri.....	58
Çizelge 8.3 Veri seti değişkenlerinin korelasyon değerleri. ....	60
Çizelge 8.4 Bağımsız değişken optimizasyonu sonrası performans değerleri.....	61
Çizelge 8.5 Konum kestirimi performans değerleri.....	69



## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

$R^2$  : Determinasyon Katsayısı

## **KISALTMALAR**

İHA	: İnsansız Hava Aracı
ML	: Makine Öğrenmesi
IMU	: Dahili Ölçüm Birimi
AHRS	: Duruş ve Yönetlim Referans Sistemi
ÇDR	: Çoklu Doğrusal Regresyon
PR	: Polinomial Regresyon

## BÖLÜM 1

### GİRİŞ

İnsansız hava araçları (İHA) günümüzde gözetleme, keşif, askeri taarruz, taşımacılık, kamera çekimi ve yangın söndürme gibi alanlarda sıklıkla kullanılan; yer kontrol istasyonundan kumanda edilebilen veya bir uçuş rotası süresince seyrüseferini tam otonom olarak tamamlayabilen araçlardır.

İHA'ların kontrolünde en önemli noktalardan biri konum ve durum bilgileridir. Konum bize aracın dünya üzerinde nerede olduğunu, durum ise fiziksel olarak nasıl bulunduğunu bildirmektedir. Bu bilgilerin doğruluğu ve hassasiyeti, aracın uçuşu devam ettirebilmesine ve yapacağı görevi yerine getirebilmesinde kritik ölçüde etki etmektedir.

Değişken dış koşullar içerisinde havada hareket eden araçların bu bilgileri doğru ve hassas olarak elde edebilmeleri için çeşitli sensörler ve sistemler kullanılmaktadır. Bu bilgi kaynakları mikro elektro-mekanik sistemler (MEMS) ve radyo haberleşmesi ile Doppler etkisini kullanan sistemler olması sebebiyle çevresel gürültülere karşı çok hassastırlar.

Gürültülü elde edilen verilerin; doğruluğunun ve hassasiyetinin düşük olması onları ham bir şekilde kullanılamaz kılmaktadır. Günümüzde bu verilerin doğruluğunun artırılması amacıyla farklı sensörler ve sistemlerden alınan, aynı bilgiyi ifade eden verilerin, harmanlanması yöntemi kullanılmaktadır. Bu yöntem sensör füzyonu olarak adlandırılmaktadır.

Seyrüsefer sırasında telemetri verilerin yer istasyonuna iletilmesi ve dahili depolama alanlarında depolanması, verilerin uçuş sonrası işlenebilirliğini mümkün kılmaktadır. Uçuş sırasında üretilen verilerin daha sonra işlenmesi, sensörlerin

hassasiyeti ve karakteristiklerini anlayabilmek için önemlidir. Bu verilerin işlenmesi ve anlamlandırılması uçuş sırasında ihtiyaç duyulan konum ve durum bilgilerinin doğruluk ve hassasiyetini artırmak için önem arz etmektedir.

Uçuş sonrası elde edilen telemetri uçuş verileri, makine öğrenmesi yöntemleri ile veriler arasında bir bağ kurularak anlamlı ifadeler üretmek mümkün hale gelmiştir. İşlenen ham verilerin, ifade ettiği bilgileri makineye öğretmek uçuş sırasında o verilerin kullanılması, istenilen verilerin hassasiyet ve doğruluklarını artırmak için olumlu bir gelişmedir.

Bu tez çalışmasında, İHA'lar için konum kestirimi yapılırken, son yıllarda hızlı bir gelişim gösteren Makine Öğrenimi yöntemi ile sensör füzyonu çalışması yapılmıştır. Makine öğrenimi algoritmalarından doğrusal regresyon ile uçuş verileri işlenmiş ve konuma dair bilgiler üretilmiştir. Mevcut sensör füzyonu algoritmaları ile karşılaştırılması yapılarak sonuçları gözlemlenmiştir.

## BÖLÜM 2

### LİTERATÜR TARAMA

Dünyada deniz, hava ve kara üzerinde bir noktadan başka bir noktaya seyahat etmek seyrüsefer olarak adlandırılır. Tarih boyunca hareket halinde olan insan gittiği yeri, mesafeyi, varış zamanını sürekli olarak bilmek istemiştir. Bu ihtiyaca binaen hesaplamalar üzerine oldukça geniş araştırmalar ve geliştirilmeler yapılmıştır.

Havacılık tarihinin dönüm noktalarından biri olarak kabul edilen radyo sistemlerinin seyrüsefer hesaplarında kullanımı ile insansız araçların komutasında yeni bir dönem başlamış oldu. Fakat bu sistemler beraberinde seyrüsefer hesaplamaları yaparken aracın dışındaki sistemlere bağımlılık problemini getirdi.

Seyrüsefer sistemlerinin hassasiyeti Küresel Seyrüsefer Uydu Sistemlerinin (GNSS) gelişimiyle beraber artmıştı. ABD'ye ait Küresel Konumlandırma Sistemi (GPS) 1990'lı yıllarda sivil kullanıma açılmıştı, fakat sinyaller üzerinde bozucu etken bulunuyordu ve hassasiyetleri çok düşüktü[1]. 2000'li yıllarda sinyallerdeki bozulmaları da kaldırarak sivil kullanıma açılmasıyla beraber seyrüsefer sistemlerindeki çalışmalarda hız kazanmıştır[2].

GNSS, erişimin sağlandığı yerlerde bir insansız sistemin kontrolü için gerekli hassasiyeti sağlayabilmektedir. Fakat çok düşük frekansta çalışıyor olması çoğu zaman kesilmelere sebebiyet vermektedir ayrıca farklı ülkelere ait bu sistemler, araçları dışa bağımlı olarak kontrole muhtaç bıraktığından dolayı hesabi seyrüsefer sistemlerinin geliştirilmesi büyük önem arz etmektedir.

Dahili sistemlerin kullanılarak seyrüsefer hesabının yapılması çalışmaların da çeşitli yöntemler geliştirilmiştir. Bunlardan biri Ataletsel Seyrüsefer Sistemi (Inertial

Navigation System - ASS) olarak adlandırılan ivmeölçer ve açıölçer sensörlerini kullanarak konumunun belirlenmesi prensibine dayanmaktadır.

Dahili sensörlerin kullanımında oluşan gürültü sebebiyle birtakım saplamalar meydana gelebilmektedir. Bu alandaki çalışmalar mevcut sistemleri desteklemek ve doğruluğunu artırmaya yönelik yapılmaktadır.

ASS ve GPS ile hassasiyeti artırmayı hedefleyen Chang Sun ve arkadaşları 2003 yılında yayınladıkları çalışmaları ile GPS kesilmelerini ASS sensörlerini füzyonu ile başardıklarını söylemişlerdir[3]. Yine aynı yıl Christopher ve arkadaşları yaptıkları çalışmada Kalman Filtresi ile bu hassasiyetin daha da iyileştirildiğini söylemişlerdir[4].

Jinling ve arkadaşları tarafından 2008 de mevcut GNSS ve ASS sistemlerine ek olarak görüntüleme yöntemi ile seyrüsefer sistemine hassasiyet katmayı başardıklarını belirtmişlerdir[5].

Günümüze kadar GNSS olmayan alanlarda seyrüsefer hesaplamaları birçok çalışmada farklı yöntemler denenmiştir. Düşük maliyetli sensörlerin hassasiyetini artırmak için hibrit yöntemler üzerine çalışan Zheng ve arkadaşları 2016 yılında makine öğrenimi ve Kalman filtresi algoritmasının tahminleme sürecine etkilerini yayınladı[6], yine aynı konuda Mustafa vd. 2018 de yayınladıkları çalışmalarında genişletilmiş Kalman filtresi ve Makine Öğrenmesi ile hibrit akıllı seyrüsefer sistem tasarımının sonuçlarını paylaşmış ve GNSS erişimi olmayan ortamda başarılı bir şekilde konum tahmini yaptıklarını belirtmiştir[7].

2019 yılında Fadi Al-Turjman, konumlandırma yapan İHA'ların, konumlandırma probleminde makine öğrenimi yöntemleri ile hassasiyet kazandırdığını belirtmiştir, yine aynı yıl bu tür uygulama örneklerini içeren kitabını yayımlamıştır[8][9].

Yine GNSS kesintileri ve hassasiyetinin artırılması konusunda makine öğrenimi metodunun kullanıldığı; 2011 yılında Muhammed Atia vd. [10], 2015 de Xinglong Tan vd. [11], 2016 yılında Ikram Belhajem vd. [12], 2017 yılında Yu Jiao vd. [13], Li

Jing vd. [14], 2018’de Abdolkarimi vd. [15], Ikram Belhajem vd. [16] ve Di Wang vd. [17], 2020 yılında ise Mehdi ve arkadaşları[18] tarafından yapılan çalışmalar literatür tarama da karşımıza çıkmaktadır.

Son yıllarda hızlanan makine öğrenmesi ve yapay zekâ uygulamaları, bir sistemin verilerini öğrenerek o sistem hakkında gerçeğe çok yakın sonuçları tahmin edebilmektedir. Böyle bir uygulamanın seyrüsefer sistemleri için kullanılması, hesabi seyrüsefer sistemlerine yeni bir bakış açısı katmıştır.

Bu tez çalışmasında; uçuş sırasında elde edilen verilerin, makine öğrenmesi algoritması ile öğrenilerek, uçuş sırasında harici bir bağımlılık olmadan hesabi seyrüsefer sistemleri prensibine uygun olarak bir konum tahmini yönteminin geliştirilmesi hedeflenmektedir.

## **BÖLÜM 3**

### **İNSANSIZ HAVA ARAÇLARI İÇİN KONUM KESTİRİMİ**

İnsansız hava araçları (İHA) içerisinde pilot ve yolcu bulunmayan otonom ve yarı otonom kontrollü olarak, tanımlanan görevleri yerine getiren hava araçlarıdır. Yer kontrol istasyonlarından kumanda edilebilen veya rotası oluşturulduktan sonra, hangardan çıkıp kendi başına görevi tamamladıktan sonra yeniden hangara girebilecek kadar otonom hale getirilebilen sistemlerdir. Yaygın olarak sivil ve askeri alanlarda kullanımı mevcuttur. Ülkemizde son yıllarda askeri kullanım alanlarındaki başarıları ile gündeme gelmektedir.

İHA'lar ilk olarak birinci dünya savaşı yıllarında üretilmiş olup, daha çok gözlem ve istihbarat için kullanılmıştır. İHA'ların kullanım alanları günümüzde askeri alanların yanı sıra keşif, trafik gözlem, arama kurtarma ve yangın söndürme gibi çeşitli alanlarda kullanılmaya başlanmıştır.

#### **3.1. İNSANSIZ HAVA ARAÇLARININ SINIFLANDIRILMASI**

İHA'lar teknik açıdan kanat tiplerine göre döner kanatlı ve sabit kanatlı olmak üzere iki sınıfa ayrılmaktadırlar.

Döner kanatlı sistemler, uçuş için bir veya birden fazla rotora sahip olan hava araçları olarak tanımlanmaktadır. Yaygın örnekleri Helikopter, Quadcopter olarak karşımıza çıkmaktadır. Döner kanatlı sistemlere örnek olarak Şekil 3.1'de Baykar tarafından geliştirilen helikopter gösterilmiştir.





Şekil 3.1 Döner kanatlı insansız hava aracı örneği (helikopter), Baykar Malazgirt.

Sabit kanatlı sistemler ise motorlarının itki kuvvetiyle yatay olarak ileriye hareketi sonucu, hava hızının oluşturduğu taşıma kuvvetiyle kanatları yardımıyla havalanan hava araçlarıdır. Sabit kanatlı sistemlere örnek olarak Şekil 3.2’de Baykar Makina tarafından geliştirilen Bayraktar TB2 gösterilmiştir.



Şekil 3.2 Sabit kanatlı hava aracı örneği, Bayraktar TB2.

## 3.2. AVİYONİK SİSTEMLER

Aviyonik sistemler bir uçak içerisinde bulunan bütün elektronik parçalara verilen genel bir isimlendirmedir. Bir uçağın aviyonik sistemleri uçağın kontrolü, takibi, iletişimi, seyrüseferi (navigasyon), meteoroloji kontrolü gibi kritik görevleri yapan elemanlardan oluşmaktadır.

### 3.2.1. Ataletsel Ölçüm Birimi (IMU)

Ataletsel ölçüm birimi (Inertial measurement unit - IMU) ivmeölçer, dönüölçer (jiroskop) ve manyetometrelerin bir arada kullanılarak oluşturulan bir ölçüm birimidir.

#### 3.2.1.1. İvmeölçer

İvmeölçer, içerisinde bulunan bükülme kollarına bağlı küçük bir plaka içerir. Fiziksel olarak algıladığı hızlanmada bu plaka döner ve kapasitans değişimine sebep olur böylelikle bu kapasitans değişikliği ölçülür ve ivme değeri bulunur.

İvmeölçerlerin çıktısı şu şekilde gösterilir:

$$y_{acc} = k_{acc}A + \beta_{acc} + \eta_{acc} \quad (3.1)$$

Bu denklemde  $y_{acc}$  yapılan ölçüm sonucu olarak Volt cinsinden çıktısı,  $k_{acc}$  kazanç,  $A$  ise ivme değeridir  $m/s^2$  cinsindedir.  $\beta_{acc}$  ise sapma değeri iken,  $\eta_{acc}$  ise sistemin gürültü değerini ifade etmektedir.

$\beta_{acc}$  değeri genellikle sensörlerin uygulama notalarında verilen değerlerdir, fakat araç havalandırmadan önce yeniden hesaplanıp matematiksel modelinin çıkartılması önemlidir. Temel olarak bu değer değişmesine etki eden faktör sıcaklıktır. Bu hususta kullanım için fabrika kalibrasyonunu kullanmak en iyi çözüm olacaktır.

Denklem 3.1 temel ivmeölçerler için kullanılabilecek bir matematiksel ifade olmasına karşın, ayrıntılı bir şekilde incelendiğinde şöyle ifade edilmektedir[19]:

$$\begin{pmatrix} a_x \\ a_y \\ a_z \end{pmatrix} = \frac{dv}{dt_b} + w_{b/i} \times v - R_v^b \begin{pmatrix} 0 \\ 0 \\ g \end{pmatrix} \quad (3.2)$$

Dolayısıyla;

$$a_x = u + qw - rv + g \sin \theta + \eta_{accel,x} \quad (3.3)$$

$$a_y = v + ru - pw - g \cos \theta \sin \Phi + \eta_{accel,y} \quad (3.4)$$

$$a_z = w + pv - qu - g \cos \theta \cos \Phi + \eta_{accel,z} \quad (3.5)$$

Görüldüğü gibi her ivmeölçer lineer ivmeyi, Coriolis ivmesini ve yerçekimi ivmesini ölçer.

Sensör eksenini ve İHA eksenini hizalanır aynı ekseninde birleştirilirse, bu üç eksen ivmesi ölçülebilir. Ölçüm ivmesi sonucunda bu ivme değerleri kullanılmadan önce yerçekimi ivmesi ve Coriolis ivmesi denklemden çıkarılmalı ve sonuçta gerçek ivme değerleri bulunabilir.

### 3.2.1.2. Dönüölçer (Jiroskop)

Dönüölçerler, üç eksen üzerinde, içerisinde bulunan titreşim kolları vasıtasıyla açısız hız ölçümü yapmaktadırlar. Kol açısız bir dönüş yaptığında Coriolis etkileri değişir, bu değişim titreşim frekansını etkiler dolayısıyla bu frekans değişikliği ile açısız hız ölçümü gerçekleştirilir.

Açısız hız çıktısı şu şekilde ifade edilir:

$$y_{gyro} = k_{gyro}A + \beta_{gyro} + \eta_{gyro} \quad (3.6)$$

Bu denklemde  $y_{gyro}$  Volt cinsinden dönme hızı ölçümüne karşılık gelirken,  $k_{gyro}$  bir kazanç değeridir.  $\beta_{gyro}$  ise sapma değerinin ön tahminini ifade eden terimdir.  $\eta_{gyro}$  ise oluşan gürültü terimidir.

### 3.2.1.3. Manyetometre

Manyetometre, dünyanın manyetik alanını ölçen ve yön bulan bir pusula olarak kullanılır. Dünyanın manyetik alan vektörleri, manyetik alanın dünyanın kutuplarına normal aktığı ve vektörlerin ekvatorda paralel olduğu ortak bir manyetik dipole benzer şekilde davranır. Manyetometre, manyetik alanın yönünü yerel olarak ölçer ve yön göstergesi sağlar. Manyetik kuzeye göre ölçülen yön. Manyetik Kuzey'de 0°dir ve manyetik Kuzey'den saat yönünde yön değişimi sırasında pozitif olarak değişir.

Manyetometre tarafından ölçülen manyetik alan çıktısı matematiksel olarak şu şekilde ifade edilir:

$$y_{mag} = \psi + \beta_{mag} + \eta_{mag} \quad (3.7)$$

Denklem de  $y_{mag}$  volt cinsinden ölçülen manyetik alanı ifade eder.  $\psi$  ise Gauss cinsinden ölçülen manyetik alan,  $\beta_{mag}$  üretici tarafından belirlenen sapma katsayısı,  $\eta_{mag}$  ise hata terimini ifade etmektedir.

### 3.2.2. Duruş ve Yönelim Referans Sistemi (AHRS)

Duruş ve yönelim referans sistemi (Attitude And Heading Reference System – AHRS) IMU yardımı ile üç eksen de hava araçlarının duruş, yön ve pozisyon bilgilerini üreten dahili sistemlerdir.

Genelde Euler açıları olarak ifade edilen Dikilme, Baş ve Yatış açılarını ifade eden bilgiler üretmektedir.

### 3.3. SEYRÜSEFER SİSTEMLERİ

Dünya havacılık tarihinde üzerine en çok çalışma yapılan alanlardan birisi de seyrüsefer sistemleridir. Uçak ile kara üzerinde yapılan uçuşlarda coğrafi işaretler kullanılabilirdi, fakat kıtalar arası yapılmak istenen bir uzun menzilli uçuşun büyük bir kısmı deniz üzerinde olacağından coğrafi işaretlerin okunması yetersiz kalıyor, istenilen yere ulaşabilmek için hatasız pilotaj sağlanması gerekiyordu.

Charles Lindberg havacılıkta yeni bir sayfa açarak Kuzey Atlantik-Paris arası uçuşu tek başına gerçekleştirmiştir. Bu başarısının ardında ise yaptığı detaylı seyrüsefer çalışmaları vardı. Bu uçuşa hazırlanırken New York-Paris arasındaki sahayı içerisine alan havacılık haritaları ve Kuzey Atlantik'deki rüzgar yönlerini gösteren haritalar bulmuş, bunlar ile gerekli seyrüsefer hesaplamalarını yaparak uçuşunu başarılı bir şekilde gerçekleştirmiştir. Böylelikle havacılık tarihine hesabi seyrüsefer sistemlerinin temellerini atmıştır.

Günümüz havacılık tarihinin geldiği son noktada ise insansız gerçekleştirilen uçuşlar karşımıza çıkmaktadır. İnsansız Hava Araçları (İHA) planlanan güzergahta, verilen görevleri yerine getirmesi beklenen askeri ve sivil amaçlarla kullanılan sistemlerdir.

İHA'lerden beklenen bu görevlerin yerine getirilmesindeki en önemli rol ise seyrüsefer sistemlerine düşmektedir. Seyrüsefer, hareket halindeki bir aracın konum ve hızının bulunmasıdır. Hava Seyrüsefer sistemleri ise uçuşun kalkış aşamasından inişine kadar takip edeceği güvenli ve en kısa uçuş rotası olarak tanımlanmaktadır [20].

Bu çalışmada havacılığın erken yıllarından, günümüz teknolojilerine kadar gelen İHA'lar için seyrüsefer sistemleri, hususi ile hesabi seyrüsefer sistemlerinden ataletsel seyrüsefer sistemi incelenmiştir.

### 3.3.1. Temel Seyrüsefer Sistemleri

Temel seyrüsefer sistemlerini Harita Okuma (Pilotaj), Yıldızlarla Seyrüsefer (Celestial Navigation), Hesabi Seyrüsefer (Dead Reckoning) ve Radyo Seyrüseferi (Radio Navigation) olarak dört ana yöntem olarak karşımıza çıkmaktadır [21].

Harita Okuma (Pilotaj): Harita kullanılarak, coğrafi işaretleri takip edilmesi ile gerçekleştirilen seyrüsefer yöntemidir.

Yıldızlarla Seyrüsefer (Celestial Navigation): Özel olarak belirlenmiş 57 yıldız ve güneş, ay, gezegenler (Venüs, Jüpiter, Satürn)'den yararlanılarak gerçekleştirilen seyrüsefer yöntemidir.

Radyo Seyrüseferi (Radio Navigation): Çeşitli frekanslarda ve çalışma prensiplerine sahip cihazlar yardımı ile yapılan seyrüsefer yöntemidir.

Hesabi Seyrüsefer (Dead-Reckoning, DR): Uçuşun kalkış ve iniş arasındaki tüm durumların planlanmasıyla; mesafe, uçuş istikameti, havada geçen zaman ve yer süratinin etkilerini hesaplanarak hiçbir cihazdan yardım almaksızın aracın konumunun ve hızının bulunmasına dayalı seyrüsefer yöntemidir.

Bu temel seyrüsefer sistemlerinden Harita Okuma (Pilotaj), Yıldızlarla Seyrüsefer (Celestial Navigation) sistemleri pilotun anlık olarak gözlemlerine dayandığından İHA'lar için kullanılması uygun yöntemler değildir.

### 3.3.2. Radyo Seyrüsefer Sistemleri

Radyo seyrüsefer sistemlerinin tamamı radyo sinyallerinin yayılma prensibinin hesaplanması temeline dayanmaktadır. Kaynaktan çıkış ve dönüş zamanı ya da yayılma zamanı gibi faktörlerin hesaplanmasıyla konum ve hız bilgisi elde edilmektedir.

Bu sistemler uçuş ya da yerde konumlandırılarak, uçak üzerinde uygun bir alıcı ile haberleşmesi neticesinde konum ve hız bilgilerinin bulunması yöntemidir. Günümüzde en gelişmiş ve hassas sistem olarak GPS sistemi kabul edilmektedir. Bu sistem çalıştığı ilk 1989 yılından beri yüksek doğruluk sağlayarak seyrüsefer sistemlerinin kabiliyet gelişiminde büyük rol oynamıştır. GPS öncesinde ise birçok sistem kullanılmıştır.

Bu sistemler çalışma prensiplerine göre üç ana sisteme ayrılır.

- 1. Dairesel Sistemler:** Uçak ile yer istasyonu arasındaki elektromanyetik dalganın gidiş-geliş zamanının hesaplanması prensibine dayanır.
- 2. Hiperbolik Sistemler:** İki ayrı yer istasyonunun eş zamanlı gönderilen sinyallerin uçak tarafından alınarak iki sinyal arasındaki gecikme farkının hesaplanması prensibine dayanır.
- 3. Açısal Sistemler:** İşaretin gidiş-dönüş zamanı yerine, istasyona veya uçağa göre dairesel ve açısal olarak hesaplanması prensibine dayanır.

Bu sistemler geliştirilirken, ihtiyaç doğrultusunda kullanım alanlarına göre en iyi sonucu verecek şekilde planlanmışlardır. Yine bu sistemler kullanım alanlarına göre Uzak, Orta ve Kısa mesafelerde kullanılan seyrüsefer sistemleri olarak üç ana sisteme ayrılmaktadır [22].

- 1. Uzak Mesafe Sistemleri:** 300 NM (NM: Deniz mili, 1 NM = 1852 Metre) ve daha fazla mesafeli uçuşlar için deniz ve çöl üzerinde kullanılan sistemlerdir. VLF (3 - 30 kHz), LF (30 - 300 kHz) veya MF (300 kHz - 3 MHz) bant genişliğini kullanmaktadır.
- 2. Orta Mesafe Sistemleri:** 300NM'den kısa mesafeli uçuşlarda kullanılmaktadır. MF (300 kHz - 3 MHz), VHF (30 - 300 MHz), UHF (300 MHz - 3 GHz) bant genişliğini kullanmaktadır.
- 3. Kısa Mesafe Sistemleri:** Kısa mesafe uçuşlarında, orta mesafe sistemleri kullanıldığı gibi daha çok inişte kullanılan ek sistemler de mevcuttur. Hata payı oldukça düşüktür.

### 3.3.2.1. Uçaklarda Kullanılan Mevcut Radyo Seyrüsefer Sistemleri

Çalışma prensiplerine ve çalışma koşullarına göre ayırdığımız, uçaklarda kullanılan mevcut sistemler NDB, VOR, DME, ILS, MLS, TACAN, LORAN, OMEGA, Radyo Altimetre, RADAR ve GNSS olarak sıralanabilmektedir.

**NDB:** Havacılıkta kullanılan ilk radyo seyrüsefer sistemidir. Uçağın NDB istasyonuna göre konumunu belirler. +/-45 derecelik sessizlik konisine sahiptir to/from bilgisi vermez [23].

**VOR:** Kıtasal hava sahası, VOR ile belirlenen havayolları ile organize edilmiştir. Referans olarak manyetik kuzey alınarak bir derecelik aralıklarla 360 derecelik radyal bilgi verir. NDB'nin +/-45 derecelik sessizlik konisini telafi eder.

**DME:** 960-1215 MHz bandında çalışan, yer istasyonu ile uçak arasındaki mesafeyi veren sistemdir. Bu sistem aynı anda 100 uçağa hizmet verebilir. Uçaklar antenin görüş hattı içinde bulunmak zorundadır, arasına bir engel girdiğinde (dağ vb.) sistemden bilgi alamaz [24].

**ILS:** Havaalanlarına iniş için kullanılan bir sistemdir. Yaklaşma hattı boyunca dikey yayın yapan işaretçiler pilota pist başından olan uzaklık bilgisini verirler [25].

**MLS:** Havaalanlarına hassas iniş için kullanılan bir sistemdir. ILS'nin eksiklerini tamamlayan yeni nesil bir sistemdir. Pahalı oluşu ve uçaklar üzerinde yeni düzenlemeler gerektirdiğinden havayolu şirketleri MLS'nin kullanımına olumsuz bakmaktadır.

**TACAN:** Askeri Havacılıkta kullanılan, uçağa yön ve uzaklık bilgisi sağlayan sistemdir. VOR/DME sisteminin sivil uçaklara sağladığı yön ve uzaklık bilgisini TACAN askeri uçaklar için sağlar.



**LORAN:** Uzun menzilli uçuşlarda kullanılan bir seyrüsefer sistemidir. VOR/DME sistemindeki kısa mesafe dezavantajı bu sistemde çözülmüştür. 1000NM'dan daha geniş alana hizmet veremez [26].

**OMEGA:** Askeri sistemlerde kullanılmak üzere ABD tarafından geliştirilmiştir. Uzun menzilli uçuşlarda uçağın dünyanın neresinde olduğunu bildiren bir seyrüsefer sistemidir. LORAN'nın 1000NM dezavantajını ortadan kaldırmıştır. Dünyanın çeşitli yerlerinde ve birbirinden uzakta sekiz yer istasyonu vardır [22]. Doğruluk değeri yaklaşık 2 NM'dir [23].

**Radyo Altimetre:** Uçağın yüksekliğinin bulunması amacıyla radyo dalgalarının uçaktan gönderilerek yerden yansıtıp dönme süresinin hesaplanması prensibine dayanır.

**Radar:** Uçak üzerinde ve yerde olmak üzere farklı amaçlara hizmet eden çeşitli radar sistemleri mevcuttur. Hepsinde amaç, herhangi bir cismin varlığını ve uzaklığını tespit etmektir.

**GNSS:** Küresel Uydu Seyrüsefer Sistemi, uydu yardımıyla dünya üzerindeki bir alıcının enlem, boylam, irtifa ve yerel saat bilgilerini veren sistemlerin genel adıdır. Bugün yayın olarak kullanılan ABD GNSS uydularının özel adı olan GPS ile özleştirilir fakat, Rusya'nın GLONAS, Avrupa Birliğinin GALILEO, Çin'in BeiDou uyduları bulunmaktadır. 1980'li yıllarda sivil kullanıma açılan GPS sayesinde oldukça hassas seyrüsefer yapılabilmektedir. GNSS destekli seyrüsefer sistemleri oldukça ekonomik ve az teçhizat ile oluşturulabilmektedir.

### **3.4. HESABİ SEYRÜSEFER SİSTEMLERİ**

Hesabi Seyrüsefer Sistemleri (Dead reckoning - Parakete hesabı), hiçbir harici radyo cihazı ile haberleşme ihtiyacı duymadan, durum ve yönelim referans sisteminden (AHRS) edinilen uçağın hareketinin yön ve hız bilgilerini kullanarak, kalkış yaptığı konuma göre uzaklığını tahminler ve uçağın konumunu belirleyen sistemlerdir. Uçaklarda kullanılan başlıca hesabi seyrüsefer sistemleri Doppler / Yönelme Referans

Sistemi, Hava Veri / Yönelme Sistemi, Ataletsel Seyrüsefer Sistemi olarak üçe ayrılmaktadır [26].

#### **3.4.1. Doppler / Yönelme Referans Sistemi**

İstikamet ve yön bilgilerini AHRS üzerinden alarak, Doppler Radarı prensibi ile uçağın yer hızını ve sürüklenme hızının ölçüldüğü sistemlerdir. Genellikle helikopterler de kullanılmaktadır [7].

#### **3.4.2. Hava Veri / Yönelme Sistemi**

Hava veri bilgisayarından aldığı gerçek hava hızı ile meteoroloji ya da tahmini rüzgar hızı ve yönünü, AHRS bilgileri ile beraber hesaplayan ve uçağın gidiş yönünü bulmak için kullanılan bir sistemdir. Doppler / Yönelme Referans Sistemi ve Ataletsel Seyrüsefer Sistemine göre oldukça zayıf bir sistem olduğu için genelde takviye edici olarak tercih edilmektedir.

#### **3.4.3. Ataletsel Seyrüsefer Sistemi**

Bir aracın atalet tepkileri kullanılarak, aracın hareket yönü, hızı ve konumunun bulunması ve bilinen ilk konumunun üzerine eklenerek elde edilen seyrüsefer sistemlerine ataletsel seyrüsefer sistemi denir. Ataletsel seyrüsefer sistemleri bir hesabi seyrüsefer sistemidir.

Ataletsel seyrüsefer sistemleri; basit olarak ataletsel ölçüm birimi (IMU) dahilindeki üç eksenli ivmeölçer ve dönüölçer sensörlerinden oluşturulmaktadır. Fizikteki yol denkleminin zamana göre türevi hızı, hızın zamana göre türevi ivmeyi vermektedir kaidesi gereği ivmeölçer tarafından ölçülen değerlerin zamana göre birinci integrali ile hızı, ikinci integrali ile konum değerleri ölçülmektedir. Böylelikle harici olarak dışarıdan bir sinyal yardımı ile konumunu bulma gereği duymadan, aracın konumu belirli ölçülerde hesaplanabilmektedir. İvme vektörel bir ölçüm olduğundan dolayı büyüklüğünün yanı sıra ivmelenme yönünün de tespit edilmesi gerekmektedir.

Dönüölçer aracılıđı ile ivmelenmenin hangi yönde gerçekleştiđi kestirebilmek mümkündür [27].

Diđer seyrüsefer sistemlerine göre Ataletsel Seyrüsefer Sisteminin avantajları ve dezavantajları şöyle sıralanabilir [20]:

1. Konum, yer hızı, durum bilgilerini sağlamaktadır.
2. Yer istasyonlarına ve harici konumlandırma sistemlerine gerek duymadan tüm enlemlerde ve tüm hava koşullarında seyrüsefer bilgisi üretebilmektedir.
3. Konum ve hız bilgileri ani ve devamlıdır. Yüksek frekanslarda sürekli bilgi akışı sağlayabilir.
4. Konum ve hız bilgileri kısa zaman dilimlerinde doğrudur, zaman uzadıkça doğruluk düşmektedir.
5. Hassas sistemler üretmek oldukça pahalıdır.
6. Düşük maliyetli sistemler oldukça gürültüye sahiptir.

### **3.5. İNSANSIZ HAVA ARAÇLARI İÇİN DURUM BİLGİSİ**

İnsansız hava araçlarının uçuş ve kontrol sistemleri için bir referans noktasına göre dünya üzerinde nerede olduklarını bilmeleri ve o konumdaki fiziksel durumlarının ne olduğunu bilmeleri önem arz etmektedir. Bu verilere genel olarak durum bilgisi denilmektedir.

#### **3.5.1. Koordinat Sistemleri**

Koordinat sistemler bir referans noktasından başlayarak, belirlenen kurallara göre oluşturulmuş doğru veya eğri çizgileri ile ifade edilen sistemlerdir. Doğrusal çizgiler koordinat eksenleri olarak tanımlanmaktadır. Bir düzlem üzerine dik iki koordinat eksenini Kartezyen Koordinat Sistemi olarak adlandırılır.

Koordinatlar, uzay da cisimleri ve kendilerine özgü bilgileri içeren, bu bilgiler ile yeni bilgilerin üretimine zemin hazırlayan sistemlerdir. Örneğin bir uçağın zamana göre

hangi konumda olduđunun bilinmesi, yine ulařacađı noktanın konumunun bilinmesiyle ne kadar süre sonra varabileceđinin hesaplanması m¼mk¼n olmaktadır.

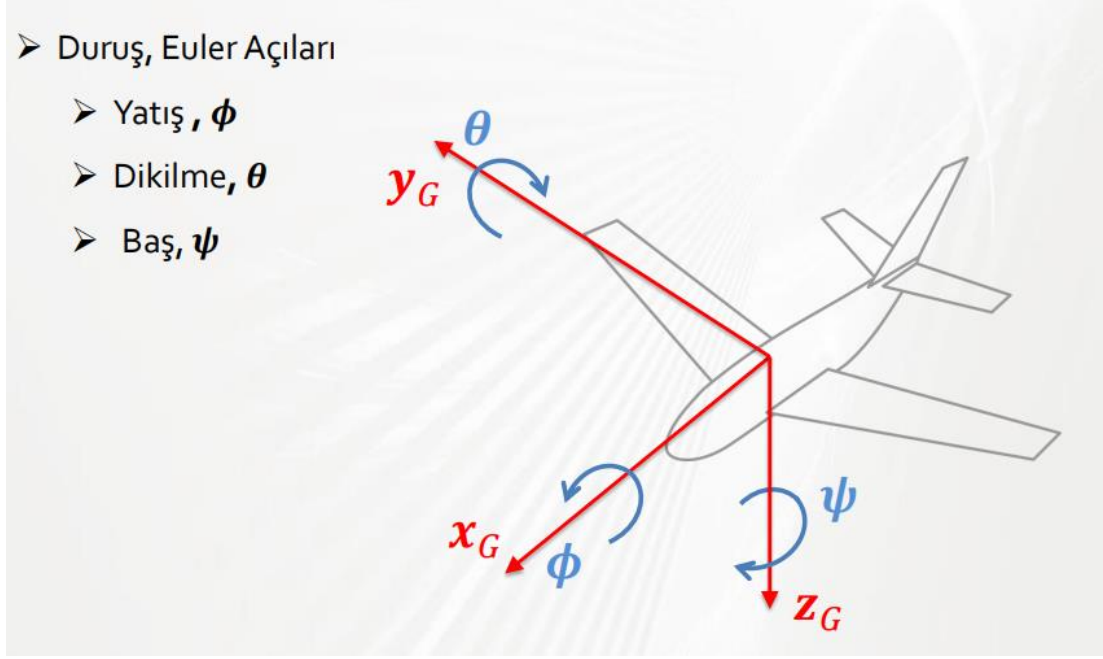
İnsansız hava araçlarının d¼nya üzerindeki konumlarının belirtirken kullanılan temel üç sistem bilgisi bulunmaktadır:

1. Enlem, Boylam, İrtifa,  $(\lambda, \phi, h)$
2. Kuzey, Dođu, Ařađı,  $(x^{NED}, y^{NED}, z^{NED})$
3. ECEF Eksen Tak. Pozisyon,  $(x^{ECEF}, y^{ECEF}, z^{ECEF})$

### 3.5.2. Duruř

Bir insansız hava aracı havada 6 serbestlik derecesine sahiptir. Euler açılıarı ifade edilen aracın üç boyutlu fiziksel durumuna duruř denmektedir. Genel olarak uçađın burnun hizası X, sađ kanat tarafı Y ve ařađısı Z ekseni olarak kabul edilir ve buralarda yaptıđı yuvarlanma hareketleri aracın duruřunu oluřturmaktadır (řekil 3.3).

Aracın X ekseni üzerinde yaptıđı yuvarlanma hareketi ile Yatıř, Y ekseni üzerindeki hareketi Dikilme ve Z ekseni üzerindeki hareketi ise Bař Açısını ifade etmektedir.

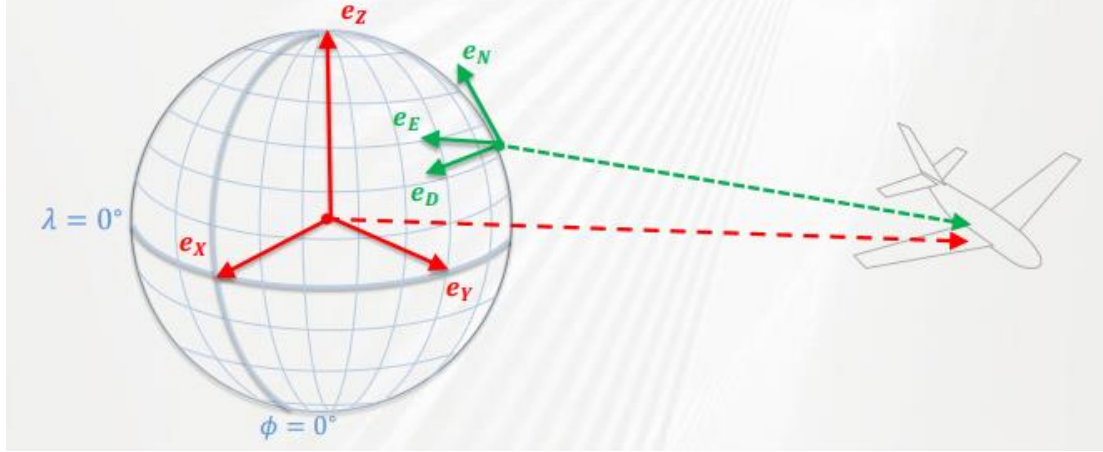


Şekil 3.3 Duruş ve Euler açıları [28].

### 3.5.3. Konum

Bir seyrüsefer sırasında araç bir noktadan diğer bir noktaya götürülmek istendiğinde anlık olarak konumunun nerede olduğunu bilinmesi gerekmektedir. Bir aracın; seyrüsefer sistemlerinden elde edilen enlem boylam ve irtifa verileri kullanılarak dünya üzerinde nerede olduğunu belirlenebilmektedir. Bunun yanı sıra matematiksel olarak daha kolay hesap yapılması ve karmaşıklıkların önüne geçme amacıyla farklı referanslarda kullanılmaktadır. Bu referanslara genel olarak koordinat sistemleri denilmektedir.

- Enlem, Boylam, İrtifa,  $(\lambda, \phi, h)$
- Kuzey, Doğu, Aşağı,  $(x^{NED}, y^{NED}, z^{NED})$
- ECEF Eksen Tak. Pozisyon,  $(x^{ECEF}, y^{ECEF}, z^{ECEF})$



Şekil 3.4 Koordinat Sistemleri ve Konum [28].

## BÖLÜM 4

### SENSÖR FÜZYONU

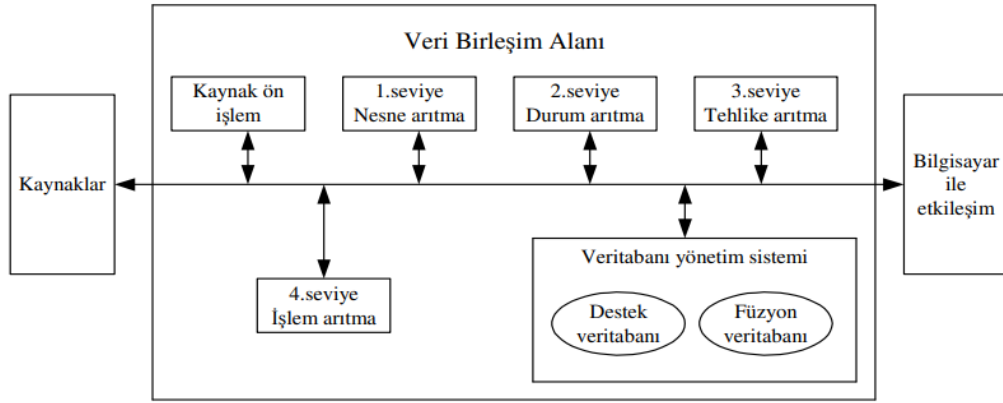
Sensör füzyonu esas olarak bir veri birleştirme problemidir. Bu yöntem, bir durumun analizi için tek bir veri kaynağından ziyade birçok veri kaynağından yararlanarak daha iyi sonuçlar üretilmesini sağlamaktadır [29].

Sensör füzyonu (sensor fusion) kelimesi; çoklu algılayıcı füzyon (multi-sensor fusion), çoklu algılayıcı veri füzyonu (multi-sensor data fusion), veri füzyonu (data fusion), algılayıcı veri füzyonu (sensor data fusion), bilgi füzyonu (information fusion), iz birleştirme (combination of evidence), gözlem sentezi (synthesis of observation) gibi tanımlamaları da içermektedir [10,11].

Bu bağlamda sensör füzyonu terimi basit ve anlaşılır gözükmesine karşın yapılan işlemler oldukça kompleks olabilmektedir. En basit bağlamda aynı bilgiyi üreten iki sensörün verilerinin ortalamalarını almak bir sensör füzyonu işlemi olarak adlandırılabilir.

#### 4.1. SENSÖR FÜZYONU YÖNTEMLERİ

Sensör füzyonu, aynı anda birçok verinin analizi ve sonuca varılması prensibini taşımaktadır. Bu yüzden matematiksel olarak yaklaşımlar çok önemlidir. Bu yaklaşımların ortaya çıkmasında askeri çalışmalar öncülük etmiştir. 1986 yılında ABD Savunma bakanlığına bağlı JDL (Joint Directors Laboratories) laboratuvarlarında geliştirilen bir model bu bağlamda yapılmış ilk çalışmalardandır. Bu çalışmaya ait akış diyagramı Şekil 4.1’de gösterilmektedir[32], [33].



Şekil 4.1 JDL modeli akış diyagramı.

Uygulamalar açısından JDL modeli oldukça kullanışlı ve genel bir kapsama sahiptir. Bu süreç modeli referans alınarak amaca yönelik sensör füzyonu uygulama yöntemleri için matematiksel modeller kullanılmıştır. Başlıca yöntemler için Bayes Teoremi, Dempster-Shafer, Oylama matematiksel modelleri kullanılmaktadır.

## 4.2. SENSÖR FÜZYON ALGORİTMALARI

İnsansız hava araçlarının durum kestiriminde karşılaşılan stokastik süreçlere yönelik çözüm amacıyla Bayes teoremini baz alan algoritmalar tercih edilmektedir. Bunların başında Kalman Filtresi ve türevleri, Tamamlayıcı filtre gibi matematiksel modeller gelmektedir.

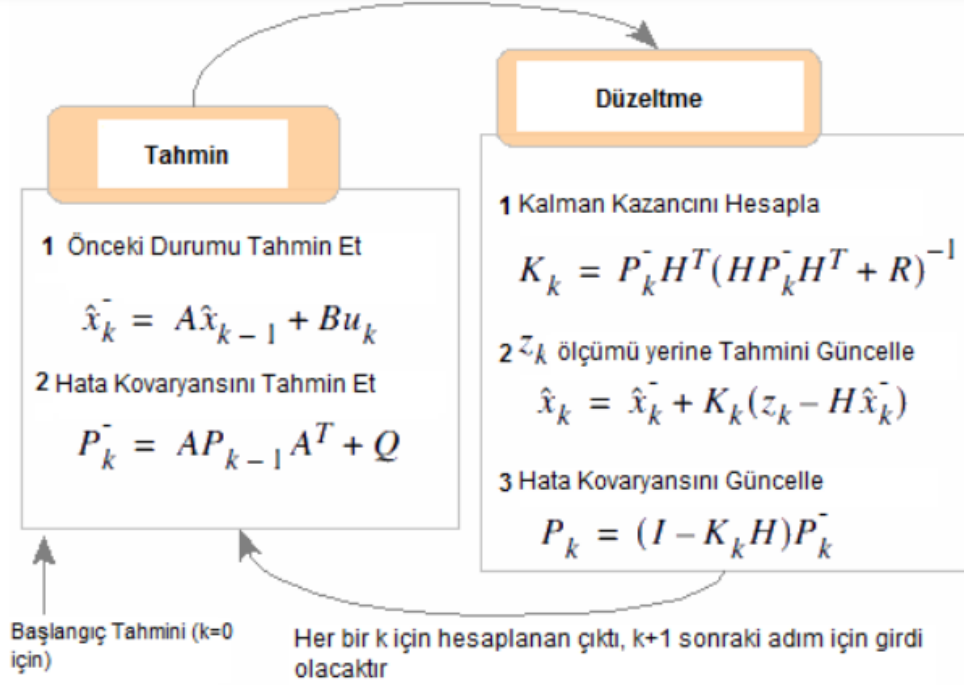
### 4.2.1. Kalman Filtresi

Stokastik Kalman Filtresi, önemli miktarda istatistiksel ve sistematik hata içeren ölçümler kullanarak sinyalleri filtrelemek için matematiksel bir model kullanır. Bu yöntem Kalman ve Bucy tarafından 1960 yılında geliştirilmiştir [12-13].

Genel olarak, bir Kalman Filtresi, bir parametrenin maksimum olasılık tahminini sağlayan ardışık zaman aralıklarında ölçülen verileri birleştirir. Girişler ve sistem durumları arasında yalnızca doğrusal bağımlılıklar olduğu sürece, birden çok sensörden gelen girdileri, ilgilenilen parametreleri içeren bir iç durum vektörüyle



ilişkilendirmek de mümkündür [36]. Kalman filtresinin genel çalışma prensibi Şekil 4.2’de gösterilmiştir.




Şekil 4.2 Kalman filtresi çalışma modeli [37].

Kalman Filtresi birçok uygulama için iyi performans gösterse de, tatmin edici sonuçlar için standart Kalman Filtresi yaklaşımının doğrusal olmayan uygulamalar için genişletilmesi gerekiyordu [38]. Bu yüzden birçok Kalman Filtresi türevidir ve sıklıkla kullanılmaktadır.

#### 4.2.2. Tamamlayıcı Filtre

Tamamlayıcı filtre, herhangi bir sensör füzyon algoritması için kullanılabilen temel filtreleme tekniğidir. Temel çalışma mantığı, iki farklı bilgi kaynağı kullanarak, bu bilgileri düşük veya yüksek geçişli filtrelerle birleştirip daha doğru ve kullanılabilir sonuçlar elde etmek olarak tarif edilebilmektedir.



Şekil 4.3 Tamamlayıcı filtre blok diyagram gösterimi.

Tamamlayıcı filtre basit olarak Şekil 4.3'te gösterilmiştir. Bu sistemde X ve Y girdileri Z sinyalinin gürültülü ölçümleri olarak ifade edilebilir. Y ölçümüne ait gürültünün çoğunlukla yüksek frekanslı olduğu ve X ölçümüne ait gürültünün düşük frekanslı olduğu varsayılarak,  $G(S)$  alçak geçiren,  $1-G(S)$  ise tamamlayıcı olarak kullanılır.

Sinyal matematiksel olarak basitçe şöyle ifade edilebilir [39]:

$$Z = \alpha_{comp}X + (1 - \alpha_{comp})Y \quad (4.1)$$

## BÖLÜM 5

### MAKİNE ÖĞRENİMİ

1642 yılında Blaise Pascal tarafından oluşturulan aritmetik makinasıyla aynı yıllarda geliştirilen modern ikilik sayı sistemi 1834 yılında bugünkü bilgisayarların atası olan delikli kart programlamanın icadına zemin hazırladı [16,17,18]. 1943 yılına gelindiğinde McCulloch ve Pitts insanın sinir ağlarının nasıl çalıştığını üzerine bir makale yazdı ve teoriyi anlatabilmek için elektronik devreler ile sinir ağı modeli oluşturdu [19,20,21]. Bu gelişmeler 1950'li yıllarda bilgisayar bilimcileri heyecanlandırarak bilgisayarlar ile yapay zekâ oluşturabileceklerini düşündüler. Bu amaç üzerine yapılan çalışmalar, matematiksel modellerin ve istatistiksel yöntemlerin kullanılmasıyla oluşan bir yapay öğrenmeyi diğer adıyla makine öğrenmesini meydana getirdi.

Denetimli derin beslemeli çok katmanlı perceptronlar için ilk genel, öğrenme algoritması Ivakhnenko ve Lapa tarafından 1965 yılında yayınlanmıştır [46]. Bu çalışmada, her katmanda, en iyi özellikler istatistiksel yöntemlerle seçilip bir sonraki katmana iletilmektedir. Ağlarını uçtan uca eğitmek için geri yayılımı (backpropagation) kullanılmamış, önceki katmanlardan sonraki katmanlara en küçük kareler yöntemi kullanılmıştır. Ivankhnenko'dan sonra ilk derin öğrenme mimarisi "Neokognitron", 1979 yılında Fukushima tarafından önerilmiştir. Omurgalı canlıların görsel sinir sistemlerinden esinlenilerek ortaya atılan yapıda, "denetimsiz öğrenme" ile kendi kendini organize eden bir ağ geliştirilmiştir. Fukushima'nın ağları modern ağlara benzer çoklu bükülme ve havuz katmanların içermektir [47]. Derin mimarilerin çoklu katmanlarında hataların geri yayılımı öğrenmenin en önemli eksikliğidir. Geri yayılım algoritmaları önceki yıllarda ortaya atılmış olsa da ilk başarılı derin sinir ağı uygulamasını Yann LeCun ve arkadaşları posta kutusu yazıları üzerinde geliştirmişlerdir [48]. Her ne kadar ağ başarılı çalışsa da, eğitiminin yaklaşık olarak 3 gün sürdüğünden pratikte uygun olmadığı görülmüştür. Bu ç

alışmadan sonra yine Yann LeCunn “LeNet” ağını kullanarak el yazısı rakamlarını (MNIST) sınıflandırmak için kıvrımlı ağlarla geri yayılımı birlikte uygulamıştır [49]. 1995 yılında Brendan Frey, Peter Dayan ve Geoffrey Hinton geliştirdikleri uyanık-uyku (wake-sleep) algoritmasını kullanarak 6’sı tamamen bağlı (fully connected), yüzlerce gizli katman içeren bir ağı, her ne kadar eğitim iki gün sürse de, eğitilmesi mümkün olduğunu göstermişlerdir [50]. 1997’de, Hochreiter ve Schmidhuber’in ortaya attığı tekrarlayan sinir ağları (recurrent neural networks) için Uzun Kısa Vadeli Bellek (long short-term memory) gibi bazı önemli gelişmeler görülmüştür [51]. Bu dönemlerde YSA algoritmaları, avantajlarına rağmen -hesaplama maliyetinden dolayı- kullanılamamış, destek vektör makineleri [52] (support vector machine) gibi probleme özgü çalışan, elle hazırlanmış özellikleri kullanan daha basit modeller, 1990’lı yıllardan 2000’lere kadar daha çok tercih edilmiştir.

Gerçek zamanlı uygulamalarda sistem çalışırken öğrenmenin devam etmesine çevrimiçi öğrenim, sistem çalışmadan önce eğitilip hazırlanan ve sisteme verilen yöntem ise çevrimdışı öğrenim olarak adlandırılmaktadır.

## **5.1. ÖĞRENME KURALLARI**

Makine öğrenmesinde eğitim için önerilen her algoritma bir kuralı temsil ediyor olsa da genel olarak ortak özelliklerine göre dört grupta incelenebilir [18][19]. Bunlar Hebb, Delta, Hopfield ve Kohonen Öğrenme Kurallarıdır.

### **5.1.1. Hebb Öğrenme Kuralı**

1950’li yıllar da başlayan yapay zekâ çalışmaları sırasında oluşturulan ilk öğrenme kuralıdır. “Bir hücre, bağlı olduğu diğer bir hücreyi etkiler.” kuralına bağlıdır. Bu kural bağlamında birçok yeni öğrenme kuralları geliştirilmiştir.

### **5.1.2. Delta Öğrenme Kuralı**

Beklenen sonuç ile hesaplanan sonuç arasındaki farkın karesi, oluşturulan sistemin hatasını verir. Bu hata minimuma indirmek için bağlantılar arasındaki ilişki sürekli değiştirilir. Çok boyutlu ağlar bu kurala göre eğitilmektedir.

### **5.1.3. Hopfield Öğrenme Kuralı**

Beklenen sonuç ile hesaplanan sonuç aynı olduğu takdirde bağlantılar arasındaki bağlantı güçlendirilir. Aksi durumda bağ zayıflatılır.

### **5.1.4. Kohonen Öğrenme Kuralı**

Bu öğrenme kuralında bağlantılar kendi aralarında yarış halindedir. En iyi ve en büyük sonucu elde eden bağlantı yarış kazanır ve kazanan bağlantının komşuluk bağlantıları güçlendirilir.

## **5.2 MAKİNE ÖĞRENİMİ ALGORİTMALARI**

Makine öğrenmesi kullanım alanları ile ilgili eğri uydurma (regression), sınıflandırma (classification), kümeleme (clustering) ve boyut küçültme gibi uygulamalar örnek verilebilir. Bu uygulamalar için oluşturulmuş birçok makine öğrenme yöntemleri mevcuttur.

Günümüzde en çok kullanılan makine öğrenmesi algoritmaları için Doğrusal Regresyon, Lojistik Regresyon, Karar Ağaçları, Destek Vektör Makinaları, Native Bayes Yöntemi, K- En Yakın Komşular Yöntemi, K-Ortalamlar, Rasgele Ağaçlar Yöntemi, Boyut İndirgeme Algoritmaları, Yapay Sinir Ağları, Kısmi En Küçük Kareler Regresyonu gibi yöntemler örnek verilebilir.

Bu çalışmada en temel makine öğrenimi algoritması olan Doğrusal Regresyon modeline ait Çoklu Doğrusal Regresyon ve Polinomial Regresyon algoritmaları kullanılarak, aralarındaki performans karşılaştırması yapılmıştır.

### 5.2.1. Çoklu Doğrusal Regresyon

Doğrusal (Linear) regresyon istatistiksel analizde çokça kullanılan bir yöntemdir. Doğrusal ve sürekli değerler için bir tahmin eğrisi oluşturmakta kullanılır. Makine öğrenimi yöntemleri arasında son yıllarda kullanımı oldukça artmış ve giriş konusu olarak kaynaklarda yer almaktadır.


Doğrusal regresyon kullanımı değişkenler arasındaki bağlantıyı anlamak ve geleceğe yönelik tahminlerde bulunmaktır. Fakat gerçek dünyada elde edilen değişkenler, çoğu kez doğrusallıktan uzak rassal bir bağlantı göstermektedir.

Doğrusal regresyon bağımsız değişken sayılarına göre Basit Doğrusal Regresyon ve Çoklu Doğrusal Regresyon olarak ikiye ayrılmaktadır. Basit Doğrusal Regresyon (5.1) tek değişkenli olurken, Çoklu Doğrusal Regresyon (5.2) ise birden fazla bağımsız değişkene sahiptir.

$$Y = \beta_0 + \beta_1 X + \epsilon \quad (5.1)$$


$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \quad (5.2)$$

Basit Doğrusal Regresyon modelini Eşitlik (5.1)'de gösterildiği üzere  $\beta_0$  kesim noktası,  $\beta_1$  doğrunun eğimi,  $\epsilon$  hata terimidir. Şekil 5.1'de Basit Doğrusal Regresyon modeline ait örnek gösterilmiştir.



Şekil 5.1 Basit doğrusal regresyon modeli[53].

Çoklu Doğrusal Regresyon parametreleri ise eşitlik (5.2)'de ifade edildiği üzere, Basit doğrusal regresyonda olduğu gibi, regresyon katsayıları  $\beta_0$ ,  $\beta_1$ , ...,  $\beta_p$  olarak ifade edilir sonunda hata katsayısı olan  $\epsilon$  bulunmaktadır. Üç boyutlu bir Çoklu Doğrusal Regresyon Modeli Şekil 5.2'te gösterilmiştir.




Şekil 5.2 Üç boyutlu bir çoklu doğrusal regresyon modeli[53].

### 5.2.2. Polinomial Regresyon

Polinomial Regresyon, lineer regresyon modeline uygun olarak istatistiksel olarak sıklıkla tercih edilen bir yöntemdir. Bağımsız değişkenlerin, bağımlı değişken ile arasındaki ilişkinin; bağımsız değişkenin n'inci dereceden bir polinom olarak modellendiği regresyon analizi biçimidir.

$$Y = \beta_0 + \beta_1 X_1^n + \beta_2 X_2^n + \dots + \beta_p X_p^n + \epsilon \quad (5.3)$$

Polinomial regresyon modeli genellikle en küçük kareler yöntemi kullanılarak uydurulur. En küçük kareler yöntemi, Gauss-Markov teoremi koşulları ile katsayıların tahmin edicilerinin varyansını en aza indirmektedir. En küçük kareler yöntemi, 1805'te Legendre ve 1809'da Gauss tarafından yayınlandı. Polinomial regresyon için ilk deneyin, Gergonne'un 1815 tarihli bir makalesin ortaya çıkmıştır. [54], [55].



Şekil 5.3 Basit bir Polinomial regresyon modeli



Bu çalışmada kullanılan bilgisayar işlemci kaynaklarının optimum kullanılabilmesi amacı ile Polinomial Regresyon yöntemi  $n=2$  olarak ikinci dereceden bir fonksiyon modellemesi oluşturulmuştur.

### 5.3. DEĞİŞKEN SEÇME YÖNTEMLERİ

Bir sistemi doğrusal model olarak tek bir veri ile ifade edebilirken bazı sistemleri birden fazla bağımsız değişken ile ifade etmek mümkündür. Bu tür sistemlerde elde edilen tüm veriler toplandıktan sonra, her bir değişkenin bağımlı olan değişken ile aralarındaki korelasyonun belirlenmesi ile makine öğrenimi sırasında sonuçları olumlu ya da olumsuz etkilediği tespit edilmesi gerekmektedir.

Çok değişkenli veri setlerinde bu tespiti gerçekleştirmek için birçok yöntem bulunmaktadır. Bu yöntemlerin başında istatistiksel metotlar gelmektedir. Öncelikle P-value değeri ve sonrasında değişken seçimi için kullanılacak veri eleme yöntemleri incelenecektir.

#### 5.3.1. Olasılık Değeri (P-Value)

Olasılık değeri (P-value), istatistiksel olarak bir sisteme etki eden örneklemelerin çoğunluğunun ne kadar etki oluşturduğunu belirlemek üzere kullanılan bir matematiksel modeldir.

- $H_0$ : Sıfır Hipotezi, beklenenin dışında bir durumun gerçekleşmediğini, ölçülen iki olgu arasında bir farkın olmadığını kabul eden genel bir önermedir.
- $H_1$ : Alternatif Hipotez, sıfır hipotez ile ortaya konulan, bir şeyin olduğunu, diğer hipotezlere göre alternatifinin bulunduğunu kabul eden bir önermedir. Alternatif hipotez her zaman sıfır hipotezinin karşıtı olacak diye bir zorunluluk bulunmamaktadır.
- P-Value: P değeri, kurulan hipotezlerin olasılık değeri. Genelde 0.05 olarak kabul edilir.

P-value küçüldükçe  $H_0$  hatalı olma ihtimali artar, büyüdükçe ise  $H_1$  hatalı olma ihtimali artar.

### 5.3.2. Veri Eleme Yöntemleri

Çok değişkenli sistemlerde verilerin optimizasyonu için değişkenlerin sonuçlara ne yönde etki ettikleri belirlenmeli ve bununla beraber olumsuz etki oluşturan değişkenlerin veri setinden kaldırılarak sonuçların iyileştirilmesi hedeflenmektedir.

İstatistiksel modellerin gelişimi boyunca bu tür değişkenlerin seçimi için yapılan birçok çalışma bulunmaktadır. Başlıca bu konuda Cox ve arkadaşları [56], Myers [57], Thompson [42-43], Hocking [60] tarafından yapılan çalışmalar literatüre kaynak sağlamaktadır.

Veri optimizasyonu için değişken seçimi ile alakalı iki temel yöntem bulunmaktadır. Bunlar; performans değerlendirmelerine göre seçim ve adım adım karşılaştırma ile seçim yöntemleridir.

Bunlar şu başlıklar altında toplayabiliriz:

- Bütün değişkenleri dahil etmek
- Geriye doğru eleme (Backward Elimination)
- İleri seçim (Forward Selection)
- İki yönlü eleme (Bidirectional Elimination)
- Skor Karşılaştırması (Score Comparison)

Bu listeden; geriye doğru eleme, ileri seçim, iki yönlü eleme yöntemleri adım adım karşılaştırma (stepwise) yöntemleridir. Belirli adımları vardır ve her adımda bir değişkeni eleyerek ilerleyen yöntemlerdir. Bütün değişkenleri dahil etme ve skor karşılaştırma yöntemleri performansa dayalı yöntemlerdir.

#### 5.3.2.1. Bütün Değişkenleri Dahil Etme Yöntemi

Bir sistem üzerinde elde edilen verilere ait değişkenlerin herhangi birini elemeyen, olduğu gibi sistem tahmini için kullanılması yöntemidir. Bu yaklaşım bazı durumlarda oldukça kullanışlı olabilir. Bunları;

- Değişken seçiminin öncesinde yapılmış olması ve değişkenlerden emin olduğumuz durumlarda
- Zorunluluk durumları (Bir modelin başarısının ölçülmesi zorunluluğu)
- Keşif için (Diğer yöntemlerin kullanılmadan önce ön fikir elde edilmesi durumu)

### 5.3.2.2. Geriye Doğru Eleme Yöntemi

Geriye doğru eleme yönteminin ilk kuralı bütün değişkenlerin dahil edilmesidir. Daha sonrasında her bir adımda P-value değerine göre başarı sağlayan değişkenlerle devam edilir diğerleri elenerek sistem iyileştirilmeye gidilir.

Kabaca adımları şu şekilde sıralanabilir:

1. P-value için sınır değeri (SD) seçilir (genel de 0.05)
2. Bütün değişkenler kullanılarak bir model inşa edilir
3. En yüksek p-value değerine sahip olan değişken ele alınır ve şayet  $P > SD$  ise 4. Adıma, değilse son adıma geçilir.
4. Bu aşamada 3.adımda seçilen en yüksek p-value değerine sahip değişken sistemden kaldırılır
5. Makine öğrenmesi güncellenir ve 3. Adıma geri dönülür
6. Makine öğrenmesi sonlandırılır.

### 5.3.2.2. İleriye Seçim Yöntemi

İleriye seçim yöntemi ise geriye doğru eleminin tam tersi olarak tek bir değişken ile başlayarak veriler eklenerek en optimum model oluşturulmaya çalışılır. Adımları şu şekilde sıralanabilir:

1. P-value için sınır değeri (SD) seçilir (genel de 0.05)
2. Bir değişken ile model inşa edilir
3. En düşük p-value değerine sahip olan değişken ele alınır

4. Bu aşamada, 3. Adımda seçilen değişken sabit tutularak yeni bir değişken daha seçilir ve sisteme eklenir
5. Makine öğrenmesi güncellenir ve 3. Adıma geri dönlür. Şayet en düşük p-value değerine sahip değişken için  $p < SD$  şartı sağlıyorsa 3. Adıma dönlür. Sağlamıyorsa son adıma geçilir.
6. Makine öğrenimi sonlandırılır.

### 5.3.2.3. Çift Yönlü Eleme

İleri seçim ve Geri eleme yöntemlerinin beraber kullanıldığı yöntemdir. Adımları şu şekildedir:

1. P-value için sınır değeri (SD) seçilir (genel de 0.05)
2. Bütün değişkenler kullanılarak bir model inşa edilir
3. En düşük p-value değerine sahip olan değişken ele alınır
4. Bu aşamada, 3. Adımda seçilen değişken sabit tutularak diğer bütün değişkenler sisteme dahil edilir ve en düşük p-value değerine sahip olan sistemde kalır
5. SD değerinin altında olan değişkenler sistemde kalır ve eski değişkenlerden hiç birisi sisten çıkarılmaz
6. Makine öğrenimi sonlandırılır.

### 5.4. DETERMİNASYON KATSAYISI (R-KARE)

Determinasyon katsayısı (belirleme katsayısı), istatistikte  $R^2$  ile gösterilen ve "R kare" olarak telaffuz edilen, bağımsız değişkenlerden tahmin edilebilen bağımlı değişkendeki varyansın oranıdır. Temel amacı, diğer ilgili bilgiler temelinde gelecekteki sonuçların tahmini veya hipotezlerin test edilmesi olan istatistiksel modeller bağlamında kullanılan bir istatistiktir.

$R^2$  değeri, açıklanabilen varyasyonun (SSR) toplam varyasyona (SST) oranı olarak tanımlanır.

$$R^2 = 1 - \frac{SSR}{SST} \quad (5.4)$$

$R^2$  değerinin yüksek olması regresyon model uyumunun iyi olduğunu gösterir. Tahmin edilen tüm değerler uydurulan eğri üzerinde olması durumunda açıklanabilen (SSR) sıfır olacağından  $R^2$  doğrudan 1'e eşit olacak ve model tam performans göstermiş olacaktır.

Ancak gerçek hayatta bağımlı değişkeni etkileyen birden fazla bağımlı değişken vardır. Bağımsız değişken sayısı arttıkça payda düşmeye devam edecektir. Böylelikle  $R^2$  düşmeyecek ve ne kadar çok değişken modele katılırsa o kadar yüksek bir uyum ortaya çıkacaktır. Bu sebepten dolayı hedef bağımsız değişkene doğrudan etki etmeyen değişkenlere ceza uygulanarak sisteme etkilerinin azaltılması gerekmektedir.

Bu ihtiyaçtan dolayı  $R^2$  yönteminde düzeltilmeye gidilerek düzeltilmiş  $R^2$  yöntemi ortaya sunulmuştur. Düzeltilmiş  $R^2$ 'nin  $R^2$ 'den farkı gereksiz eklenen bağımsız değişkenleri cezalandırıyor olmasıdır.

Düzeltilmiş  $R^2$  matematiksel olarak şöyle ifade edilmektedir:

$$\text{Düzeltilmiş } R^2 = 1 - (1 - R^2) \frac{N-1}{N-P-1} \quad (5.5)$$

Burada N örneklem büyüklüğünü, P bağımsız değişken sayısını belirtmektedir. Bu çalışmada, "Düzeltilmiş  $R^2$  değeri" doğrudan " $R^2$  Değeri" olarak ifade edilmiştir.

## BÖLÜM 6

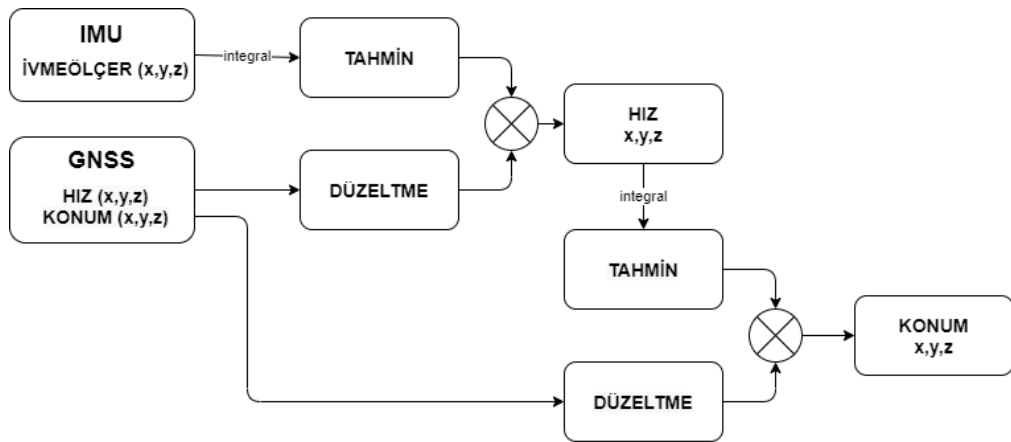
### SENSÖR FÜZYONU VE MAKİNE ÖĞRENİMİ

İnsansız hava araçları için konum bilgisi probleminin çözümü için yaygın olarak sensör füzyonu metotlarının kullanıldığından önceki bölümlerde bahsedilmiştir. Bu bölümde konum probleminin çözümü için önerilen makine öğrenimi metodunun uygulama esaslarından bahsedilip, sensör füzyonu ve makine öğrenimi arasındaki uygulama farkları ele alınmıştır.

#### 6.1. KONUM KESTİRİMİ İÇİN SENSÖR FÜZYONU MODELİ

Konum kestirimi için sensör füzyonu modeli oluşturulurken; genel tanımı, avantaj ve dezavantajlarından Bölüm 3'te bahsedilen Ataletsel Seyrüsefer Sistemi (ASS – INS) birimi modellenmiş ve süreçleri incelenmiştir.

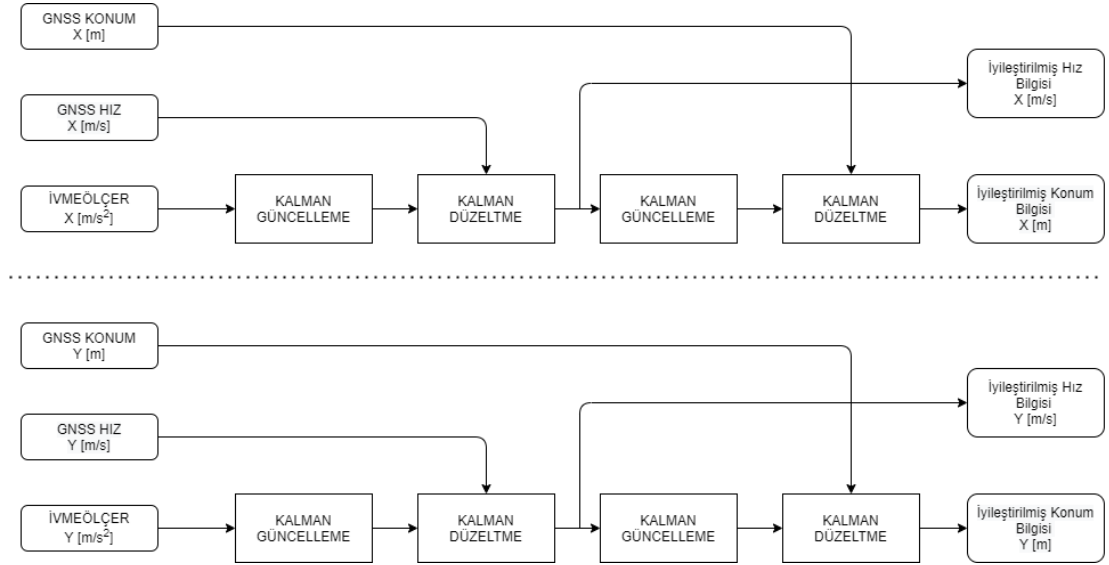
Bölüm 4'te açıklanan sensör füzyon metodu ve kalman filtresi algoritması ile oluşturulan modelin sensörlerden alınan veriler ile konum ve hız bilgilerini tahmin süreci Şekil 6.1'de ki diyagramda gösterilmiştir.



Şekil 6.1 ASS sensör füzyon modeli veri tahmin süreci.

ASS temel olarak fizik kurallarına dayanmaktadır. Konumun türevi hızı, hızın türevi ivmeyi ifade eder kuralları neticesinde ivmeölçer sensöründen alınan ivme değerinin birinci integrali hızı, ikinci integrali ise konumu bize döndürmektedir. Fakat sistemlerdeki hassasiyet ve gürültü eşiği sebebiyle biriken hata gerçek değerden uzaklaşmaya sebep olmaktadır. Bu hatayı düzeltmek için dış kaynaktan bir hız ve konum bilgisi alınarak sistem iyileştirilme ihtiyacı duyar. İyileştirme bilgisi GNSS üzerinden alınarak sistemde düzeltme sağlanır.

Bu süreç boyunca farklı verilerin birleştirilmesi için kalman filtresi algoritması kullanılmıştır. Bölüm 4'te açıklanan Kalman Filtresinin adımlarının oluşturulan ASS sensör füzyonu sürecine ait diyagramı Şekil 6.2'de gösterilmiştir.



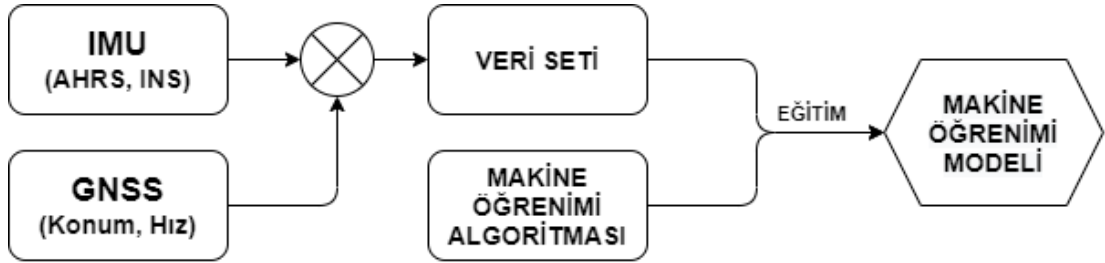
Şekil 6.2 ASS sensör füzyon modeli, Kalman filtresi algoritma süreci.

Bu süreç sırasında kalman kendi içerisinde hesapladığı kazanç faktörü ile, GNSS'in kesilmesi gibi bir durum söz konusu olduğunda sistemin tahmin sürecini hesapladığı kazanç ile devam ettirerek, konum kestirimine devam edebilmektedir. Kazanç hesaplama yönü ile güçlü olması Kalman Filtresi ve türevlerinin ASS uygulamalarında sıklıkla tercih edilmektedir.

## 6.2. KONUM KESTİRİMİ İÇİN MAKİNE ÖĞRENİMİ MODELİ

Bölüm 5’te açıklanan Makine Öğrenimi metodu ile İHA’lar için coğrafi konum bilgisinin elde edilmesi problemine çözüm olarak önerilen konum kestirimi modeli oluşturulmuş ve süreçleri incelenmiştir.

Makine öğrenimi için öncelikle uçuş sırasında araçtan elde edilen telemetri verileri ile bir paket oluşturulur ve bu paket veri seti olarak işlenir. İşlenen veri setinin, makine öğrenimi algoritmaları ile eğitilerek Makine Öğrenimi Modelinin oluşturulma süreci Şekil 6.3’te gösterilmiştir.




Şekil 6.3 Makine öğrenimi modelinin oluşturulma süreci.

Makine Öğrenimi Modeli eğitilirken, İHA üzerinden alınan telemetri verileri ile veri setinin bağımlı ve bağımsız değişkenleri oluşturulur. Bağımsız değişkenlerin sisteme girdisi ile bağımlı değişkenlerin nasıl bir sonuç gösterdiği sistem tarafından öğrenilir.

Veriler ile eğitilmiş, sistem üzerinde hazır bulunan Makine Öğrenimi Modeli, bağımsız değişkenlerin girdileri ile uçağın duruş ve hız bilgilerini alır ve daha önce öğrendiği bağımlı değişkenlerin gösterdiği sonuçlara benzer olarak konum bilgisinin tahminini yapar (Şekil 6.4).





Şekil 6.4 Makine öğrenimi modeli ile konum tahmin döngüsü.

Veri setinin yapısı, bağımlı ve bağımsız değişkenler bir sonraki bölümde detaylı olarak açıklanmıştır.

### 6.3. DEĞERLENDİRME

Konum kestirimi problemi için kullanılan metotlar incelendiğinde Sensör füzyonunun gerçek zamanlı bir çözüm ürettiği gözükmektedir. Sensörlerden gelen verilerin anlık olarak algoritmalar tarafından işlenmesi ve bu işlemenin sonucunda elde edilen algoritma kazanç katsayıları sürekli güncellenerek gerçek zamanlı olarak konum ve hız gibi değerlerin kestirimi gerçekleştirilmektedir.

Makine öğrenimi metodunun ise gerçekleşen seyrüseferlerde araçtan alınan telemetri verilerinin biriktirilmesi ve uçuş sonunda bu verilerin işlenerek veri setlerine dönüştürülmesi ile çevrimdışı bir süreç izlenmektedir. Elde edilen büyük veri setleri daha sonra makine öğrenimi algoritmaları ile eğitilerek, bir model oluşturulduktan sonra sistem üzerine entegre edilmesi ile bir konum kestirimi problemine çözüm ürettiği gözlemlenmektedir.

Bu tez çalışmasında makine öğrenimi metodunun, sensör füzyonuna benzerliği ele alınarak, makine öğrenimi destekli sensör füzyonu uygulaması gerçekleştirilmiştir.

## **BÖLÜM 7**

### **MATERYAL VE METOT**

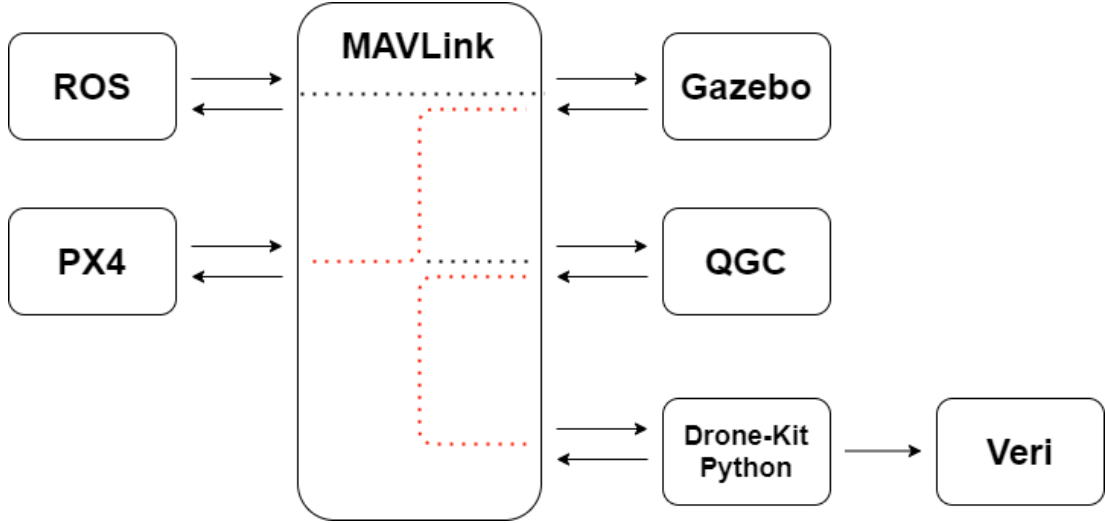
Bir İHA'nın konumunu bulabilmek için çeşitli sensörlerden alınan verilere ihtiyaç vardır. Bu veriler doğrudan konum bilgisi gönderen GPS sistemleri olabilirken, dahili bilgi üreten sensörler de olabilir.

Bu çalışmada bir İHA'nın uçuş sırasında ürettiği sensör verileri ve uçuşa dair tüm veriler makine öğrenimi algoritması yardımı ile bilgisayara öğretilmiş ve uçuş sırasında bu öğrendiği bilgileri harmanlayarak aracın yerini tespit etmesi sağlanmıştır.

Bu bölümde uçuş verilerinin simülasyon ortamında nasıl elde edildiğini ve elde edilen verilerin nasıl işlendiği anlatılmıştır.

#### **7.1. SİMÜLASYON ORTAMI**

Uçuş verilerinin elde edilmesi için Linux ortamında oluşturulan uçuş simülasyonu kullanılmıştır. Simülasyon ortamı; ROS, MAVLink, PX4 Firmware, Gazebo, QGroundControl ve Drone-Kit bileşenleri kullanılarak oluşturulmuştur. Şekil 7.1 de simülasyon organizasyonu ve haberleşme yapısı gösterilmiştir.



Şekil 7.1 Simülasyon organizasyonu ve haberleşme şeması.

### 7.1.1. Robot İşletim Sistemi (ROS)

Robot İşletim Sistemi (Robot Operating System - ROS), robot yazılımı yazmak için esnek bir kütüphanedir. Çok çeşitli robotik platformlarda karmaşık ve sağlam robot davranışı oluşturma görevini basitleştirmeyi amaçlayan bir araç, kitaplık ve kural koleksiyonudur [61].

ROS, uçuş verilerini topladığımız sabit kanatlı insansız hava aracına ait kinematik hesaplamaları yaparak simülasyon ortamında hareket kontrollerini sağlamaktadır.

### 7.1.2. MAVLink

MAVLink, dronelarla iletişim kurmak için çok hafif bir mesajlaşma protokolüdür. Kaynakları kısıtlı sistemler ve bant genişliği kısıtlı bağlantılar için tasarlanmış bir ikilik telemetri protokolüdür [62].

MAVLink, simülasyon ortamında ROS ve diğer bileşenler tarafından üretilen verilerin diğer birimlerle haberleşmesini sağlayan bir haberleşme protokolüdür.

### 7.1.3. PX4 Firmware

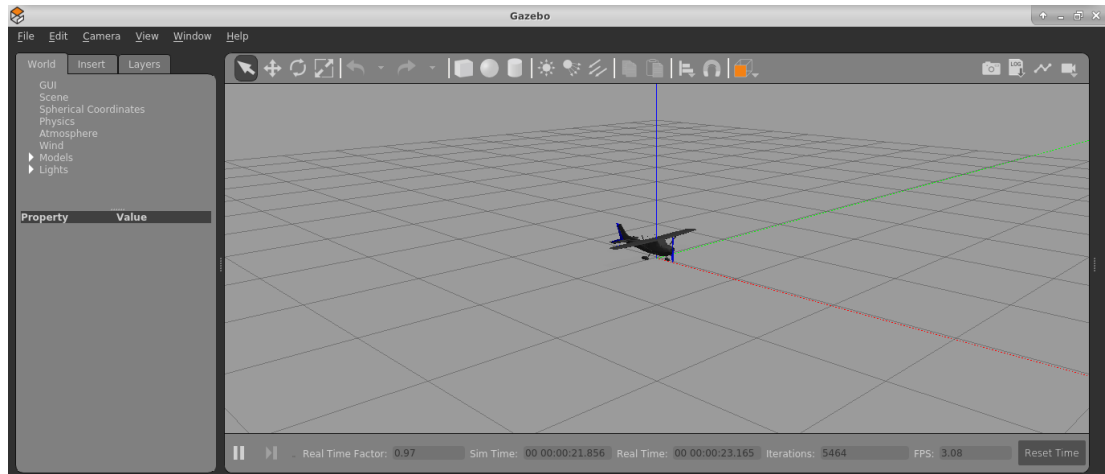
PX4, profesyonel bir oto pilottur. Endüstri ve akademisyen geliştiriciler tarafından geliştirilen ve dünya çapında aktif bir topluluk tarafından desteklenen, yarış ve kargo dronelerinden kara araçlarına ve deniz altı araçlarına kadar her türlü araca güç sağlar [63].

Bu firmware açık kaynak kodlu olarak geliştirilmiş ve herkesin kullanıma açılmıştır. Kaynak kodlarını simülasyonumuzun temelini oluşturmaktadır. MAVLink protokolünü kullanarak ROS ile haberleşme sağlar. Uçağın üzerindeki sanal dünya etkilerini ROS'a ileterek hesaplamaların yapılmasını sağlar.

### 7.1.4. Gazebo

Gazebo, karmaşık iç ve dış ortamlarda robot popülasyonlarını doğru ve verimli bir şekilde simüle etme becerisine sahip bir 3D dinamik simütatördür. Oyun motorlarına benzer olsa da Gazebo, hem kullanıcılar hem de programlar için çok daha yüksek bir doğruluk derecesinde fizik simülasyonu, bir sensör paketi ve arayüzler sunar [64].

Gazebo'nun sağladığı sanal dünya üzerinde ROS ve PX4 Firmware paketlerinin haberleşmesiyle tam bir simülasyon ortamı kurulumu gerçekleştirilmiştir.



Şekil 7.2 Gazebo kullanıcı arayüzü.

### 7.1.5. QGroundControl

QGroundControl bir yer kontrol istasyon programıdır. Gelişmiş ara yüzü sayesinde bir uçuş için gerekli tüm kontrolleri, seyrüsefer için rota oluşturma, uçuş esnasında aracı farkı bir noktaya yönlendirme gibi kullanışlı bir kontrol istasyonudur [65].

Açık kaynak kodlu olarak geliştiricilerin herkesin kullanımına sunmasıyla, PX4 gibi profesyonel oto pilotlarla birebir uyum içerisinde çalışır hale gelmiştir.

Simülasyon ortamında aracın uçuş rotasını belirlemek ve kontrollerini sağlamak için kullanılmıştır.



Şekil 7.3 QGroundControl kullanıcı arayüzü.

### 7.1.6. Python Drone-kit Kütüphanesi

Drone-kit, Python yazılım dilinin esnek yapısını kullanarak, MAVLink protokolüne erişebilen bir kütüphanedir. Python dilini kullanarak tam otonom bir uçuş programlamayı da mümkün kılmaktadır. Uçuş sırasında tüm verilerine çok az bir gecikme ile erişebilmektedir ve müdahale edebilmektedir [66].

Drone-kit kütüphanesi simülasyon ortamında uçuş verilerini toplayarak istenilen formatta kaydedebilmek için kullanılmıştır.

## 7.2. VERİ YAPISI

Uçuş sırasında toplanan veriler bir dizin içerisinde sırasıyla; t0 anına ait Enlem, Boylam, Global İrtifa, Lokal İrtifa, Hava Hızı, Yer Hızı, x-y-z eksenlerine ait anlık hız, Yuvarlanma Açısı (Roll), Yunuslama Açısı (Pitch), Yalpalama Açısı (Yaw) ve t1 anına ait Enlem, Boylam bilgileri toplanmaktadır. Verilerin açıklaması Çizelge 7.1’de örnek veriler ise Çizelge 7.2’de gösterilmektedir.

Çizelge 7.1 Veri seti değişkenleri ve açıklamaları.

Veri Adı	Birim	Açıklaması
Lat_t0, Lon_t0	deg	t0 anına ait Enlem ve Boylam (Latitude, Longitude) bilgisi.
Alt	m	Yer kürenin denize göre irtifa bilgisi. Rakım üzerine mevcut irtifa eklenmiş hali.
Alt_rel	m	Başlangıç rakımını sıfır kabul eden irtifa değeri.
Airspeed	m/s	Aracın, pitot tüpü ile ölçtüğü hava hızı değeri
Groundspeed	m/s	GPS ve dahili sensörler ile ölçülen gerçek yere göre hız.
Vx, Vy, Vz	m/s	Aracın NED eksenlerine göre anlık hızları
Roll, Pitch, Yaw	rad	NED eksenine göre Yuvarlanma, Yunuslama ve Yalpalama açıları
Heading	deg	Aracın Kuzey Kutbuna göre baş açısı
Lat_t1, Lon_t1	deg	t1 anına ait bağımlı Enlem ve Boylam (Latitude, Longitude) bilgisi değişkeni.

Çizelge 7.2 Veri seti örnekleri.

lat_t0	lon_t0	alt	alt_rel	airspeed	groundspeed	vx	vy	vz	roll	pitch	yaw	heading	lat_t1	lon_t1
40,0082726	26,9763463	487,87	-0,455	18,96606636	20,40005112	-1,72	0,89	20,32	0,049477469	-0,053635098	1,686901927	96	40,0082578	26,97672
40,0082578	26,97672	488,884	0,557	23,04180908	23,36873055	-2,65	-2,75	23,21	0,189162657	0,115178458	1,701052308	97	40,0082354	26,97697
40,0082354	26,97697	493,971	5,645	22,61750984	22,03444862	-3,82	-6,34	21,61	0,180333048	0,268459409	1,777261376	101	40,0082022	26,9772024
40,0082022	26,9772024	501,062	12,736	21,53185463	20,32667923	-3,35	-7,16	19,93	-0,053772796	0,29306522	1,78241539	102	40,0081743	26,9774287
40,0081743	26,9774287	507,069	18,743	20,77505875	20,38005829	-2,1	-5,6	20,27	-0,118199356	0,225119993	1,718136311	98	40,0081577	26,9776602
40,0081577	26,9776602	512,333	24,007	20,63726616	20,24022102	-0,78	-5,33	20,2	-0,110625647	0,21601665	1,658726692	95	40,0081512	26,9778838
40,0081512	26,9778838	517,255	28,929	20,33033562	20,04935265	0,07	-5,22	20,04	-0,085394189	0,212774843	1,61520803	92	40,0081508	26,9781011
40,0081508	26,9781011	521,981	33,655	20,07325745	19,86052895	0,54	-5,14	19,84	-0,063324042	0,211325899	1,588456631	91	40,0081539	26,9783213
40,0081539	26,9783213	526,733	38,407	19,77639198	19,62874031	0,78	-5,04	19,61	-0,05137717	0,210436881	1,571836948	90	40,008159	26,9785427

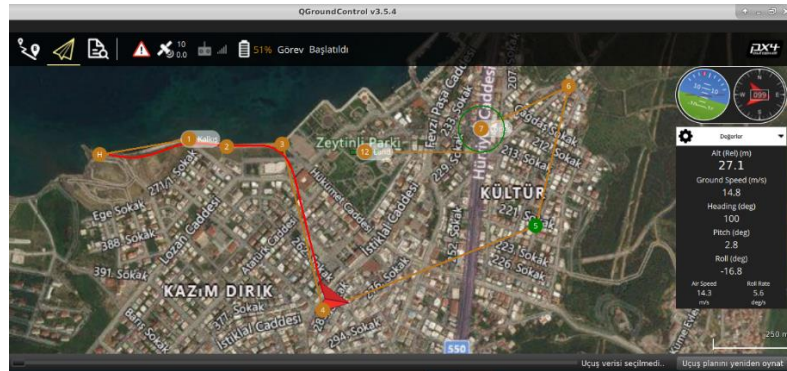
### 7.3. VERİ SETİ

Makine öğreniminde kullanılan Çizelge 7.2’de örnekleri gösterilen veri seti, otuz farklı konum üzerinde gerçekleştirilen çeşitli seyrüseferlere ait uçuşların telemetri verilerinden oluşmaktadır. Uçuşlar Türkiye sınırları içerisinde, birbirinden bağımsız konum ve seyrüsefer güzergâhları ile gerçekleştirilmiştir.



Şekil 7.4 Türkiye haritası üzerinde verileri alınan uçuşlara ait konumlar.

Veri seti oluşturulurken her uçuşa ait telemetri verileri 1 saniye zaman sekansı ile alınmıştır. Uçuşlara ait diğer bilgiler Çizelge 7.3’te gösterilmiştir. Oluşturulan veri setinin toplam veri adedi 35.115’tir. Yapılan uçuşların örnek seyrüsefer güzergâhı Şekil 7.5’te gösterilmiştir.



Şekil 7.5 İzmir uçuş seyrüsefer güzergâhının simülasyon ekran görüntüsü.

Çizelge 7.3 Yapılan uçuşların detaylı bilgileri.

S/N	Konum Adı	Enlem	Boylam	Uçuş İrtifası (Maks.)	Uçuş Hızı (Maks.)	Toplam Uçuş Mesafesi	Veri Adeti
1	Çanakkale	40.008272	26.976346	50m	15m/s	3552m	226
2	Sinop	42.029689	35.173742	100m	21m/s	2389m	175
3	Van	38.521287	43.333557	100m	23m/s	3000m	249
4	Gaziantep	36.999385	37.377143	100m	23m/s	2501m	240
5	Konya	37.679097	31.721324	50m	23m/s	7258m	371
6	Muğla	37.026059	27.411830	100m	23m/s	10000m	848
7	Ankara	39.910394	32.821494	100m	23m/s	19961m	1393
8	Hakkari	37.539276	43.673481	50m	23m/s	17684m	1211
9	İstanbul	40.996293	28.806033	150m	23m/s	12876m	692
10	Kırklareli	41.753832	27.271181	150m	23m/s	16568m	983
11	Edirne	40.780606	26.177328	250m	23m/s	19353m	1347
12	Eskişehir	39.784068	30.562526	250m	23m/s	10408m	797
13	İskendurun	36.552369	36.089348	50m	23m/s	5361m	357
14	Ordu	40.970380	38.065385	300m	23m/s	10103m	673
15	Denizli	37.783988	29.094310	50m	23m/s	9079m	640
16	Tekirdağ	40.610804	27.116744	50m	23m/s	10162m	726
17	Şanlıurfa	37.227278	39.301340	250m	23m/s	15665m	1099
18	Elazığ	38.671948	39.191300	250m	23m/s	7005m	454
19	Yozgat	39.812564	34.807242	250m	23m/s	31720m	2186
20	Sakarya	41.123894	30.557862	250m	23m/s	79215m	5814
21	İzmir	38.804248	26.962827	25m	15m/s	3081m	225
22	Kayseri	38.649476	35.451794	25m	15m/s	11838m	839
23	Kastamonu	41.304329	33.794222	25m	15m/s	23658m	1713
24	Sivas	39.710188	37.011043	250m	15m/s	17062m	1948
25	Kars	40.604467	43.095957	190m	23m/s	19523m	1435
26	Antalya	36.841673	30.612097	190m	50m/s	50186m	3286
27	Erzurum	39.874959	41.251625	190m	25m/s	52906m	3858
28	Tokat	40.683099	36.571773	190m	25m/s	7181m	585
29	Tuzgölü	39.116960	33.350676	190m	15m/s	5631m	481
30	Bozcaada	39.831035	26.061589	190m	15m/s	2228m	264



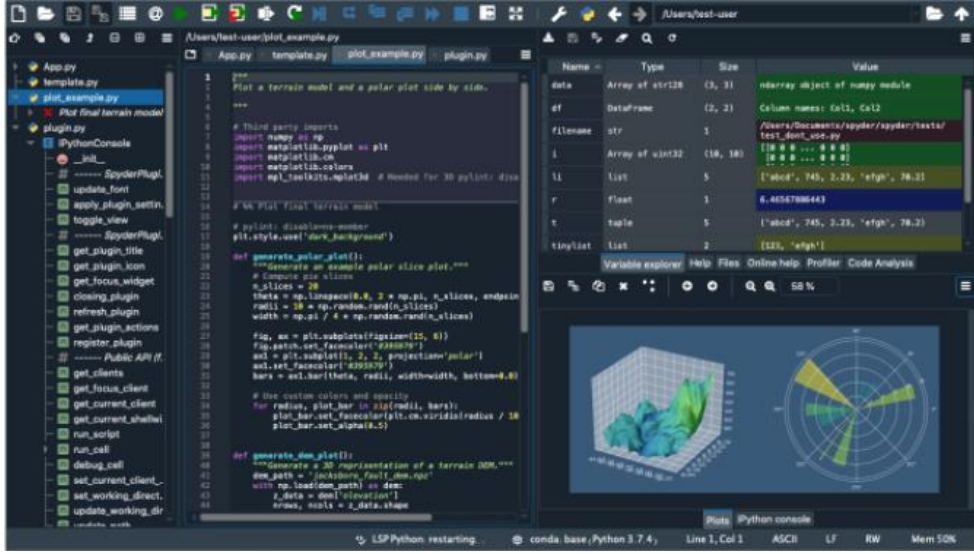
## **7.4. VERİ İŞLEME VE DENEY ORTAMI**

Simülasyon ortamında elde edilen uçuş verilerinin işlenmesi ve anlamlı sonuçlar elde edebilmek için bir sistemde eğitilmesi gerekmektedir. Makine öğrenimi; bir algoritma yardımı ile var olan veriler tarafından sistemin beslenmesi ve eğitilmesi işlemidir. Birçok farklı programlama ortamında bu işlemler yapılabildiği gibi günümüzde kaynak ve pratikliği bakımından Python programlama dili ve topluluğu sıklıkla tercih edilmektedir.

Verilerin işlenmesi için Python dilinin bilimsel çalışmalar için özelleştirilmiş bir tümleşik geliştirme ortamı olan Spyder-IDE ile makine öğrenimi kütüphanesi olan Scikit-learn kütüphanesi kullanılmıştır.

### **7.4.1. Spyder-IDE**

Spyder, Python'da yazılmış ve bilim adamları, mühendisler ve veri analistleri tarafından ve onlar için tasarlanmış ücretsiz ve açık kaynaklı bir bilimsel ortamdır. Kapsamlı bir geliştirme aracının gelişmiş düzenleme, analiz, hata ayıklama ve profil oluşturma işlevlerinin benzersiz bir kombinasyonunu, bilimsel bir paketin veri keşfi, etkileşimli yürütme, derin inceleme ve güzel görselleştirme yetenekleri ile birlikte sunar [67].



Şekil 7.6 Spyder-IDE görünümü [67].

#### 7.4.2. Python Scikit-learn Kütüphanesi

Scikit-learn, orta ölçekli denetimli ve denetimsiz problemler için çok çeşitli son teknoloji makine öğrenimi algoritmalarını entegre eden bir Python kütüphanesidir. Bu paket, genel amaçlı yüksek seviyeli bir dil kullanarak uzman olmayanlara makine öğrenimi getirmeye odaklanmaktadır. Kullanım kolaylığı, performans, dokümantasyon ve API tutarlılığı kullanıcılar tarafından oldukça önemlidir. Minimal bağımlılıkları vardır ve basitleştirilmiş BSD lisansı altında dağıtılır, hem akademik hem de ticari ortamlarda kullanılabilir [68].



Şekil 7.7 Scikit-Learn ve Python logoları

## BÖLÜM 8

### MAKİNE ÖĞRENİMİ DESTEKLİ KONUM KESTİRİMİ

Bir hava aracının seyrüsefer sırasında görevi tamamlayabilmesi için en kritik bilgilerden birisi coğrafi konum bilgisidir. Bu bilgi daha önceki bölümlerde detaylı anlatıldığı üzere GPS gibi harici sistemler kullanılarak elde edilebildiği gibi dahili sistemler kullanılarak da elde edilebilmektedir.

Bu bölümde farklı metotlar ile elde edilebilen konum bilgisinin, dahili sistemleri kullanarak Bölüm 5’de anlatılan makine öğrenimi metodu ile elde edilmesi, makine öğrenimi algoritmalarının performanslarını etkileyen veri setinin optimize edilmesi ve makine öğrenimi algoritmalarının performans karşılaştırılmaları anlatılmıştır.

#### 8.1. VERİ SETİ OPTİMİZASYONU

Ham veri setinde bulunan bağımsız değişkenler, örneklemeler mutlak olarak tahminleme sürecine pozitif etki göstermemektedirler. Bu sebepten dolayı veri setinin optimize edilmesi ile algoritmaların göstereceği performans artırılabilir.

Öncelikle veri setinin büyüklüğünün analizi yapılarak algoritmaların performans karşılaştırması yapılmıştır. Veri setinin büyüklüğü ayarlandıktan sonra bağımlı değişkenler için Geri Eleme Yöntemi kullanılarak bağımsız değişkenlerden negatif etki yapan değişkenler elenerek veri setinin performansı artırılması hedeflenmiştir.

Uçuş listesinde (Bkz. Çizelge 6.1) gösterilen uçuşların birleştirilmesi ile 29 adet veri seti oluşturulmuştur. Oluşturulan veri setleri her bir algoritma ile test edilerek optimum veri seti büyüklüğü gözlemlenmiştir.

### 8.1.1. Ham Veri Setinin Algoritma Performanslarının Değerlendirilmesi

Uçuşlardan elde edilen telemetri verilerinin birleştirilmesi ile elde edilen veri setinin mevcut makine öğrenimi algoritmaları ile makine tarafından öğrenilmesi ve girdilerin sonuçlarının tahmin edilmesi ile gerçek değerlere yakınlığının ölçülmesi bununla beraber hem ham verinin doğruluğu hem de bu veri setine algoritmaların gösterdiği performansın ölçülmesi hedeflenmiştir.

Ham veri seti, %60 eğitim, %40 test verisi olarak ayrılarak algoritmalara eğitimi yaptırılmış, çıkan sonuçların  $R^2$  başarı katsayısı metodu ile performans karşılaştırmaları yapılmıştır.

Doğrusal regresyon modeli altında Çoklu Doğrusal Regresyon ve Polinomial Regresyon algoritmaları ile oluşturulan veri setinin rastgele oluşturulmuş eğitim ve test setlerinin sonuçları Çizelge 8.1’de gösterilmiştir. Oluşturulan eğitim seti 21061 adet, test seti ise 14041 adet örneklem içermektedir.

Çizelge 8.1 Ham veri setinin performans değerlendirmesi

Algoritma	$R^2$ Değeri	Maks. Hata (m)	Min. Hata (m)	Ort. Hata (m)
Çoklu Doğrusal Reg.	0.9999999810242	16.0266	0.0023	1.1124
Polinomial Reg.	0.9999999890927	14.9385	0.0022	0.8304


Çizelge 8.1’de belirtilen sonuçlardan  $R^2$  değerinin yüksek çıkmasının temel sebebi konum bilgilerinin derece cinsinden ifade edilmesinden kaynaklanmaktadır. Tahmin edilen ve gerçek değer arasındaki fiziksel mesafe farkı ise sonuçların daha iyi okunmasına olanak sağlamaktadır.

Yine sonuçların bu denli yüksek çıkmasının sebeplerinden bir diğeri rastgele seçilmiş örneklemelerin birbirleri ile bir seri oluşturmamalarından kaynaklanmaktadır. Her bir örneklem kendi başına değerlendirilmiş olarak sonuç üretilmiştir. Bir sonraki deneyde

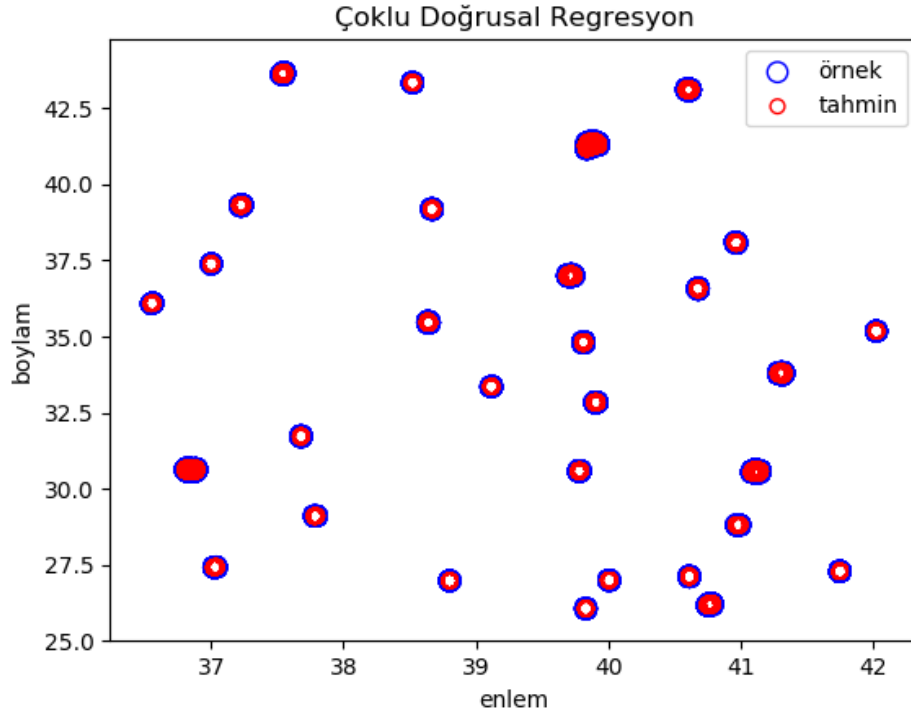
gerçekleştirilecek olan tam bir uçuşun analizinde daha net sonuçlar gözlemlenmesi beklenmektedir.

Deneydeki algoritmaların sonuçları çok benzer olduğundan örnek olarak Çoklu Doğrusal Regresyon algoritmasının sonuçları Şekil 8.1’de gösterilmiştir. Bu grafikler incelendiğinde veri setinin bazı örneklemelerinde hatanın artması, uçuş verilerinin bazı yerlerde birbirlerini tekrar etmeleri ve bu tekrar sonucunda makine öğrenimi yapılırken ezber (over-fitting) yapmalarından kaynaklanmaktadır.

Bu problemin çözümü için veri seti işleme yapılarak veri setinde olumsuz etki yapan değerliklerin kaldırılması sonuçların iyileşmesini sağlayacaktır.



(a)



Şekil 8.1 (a) ÇDR enlem boylam tahmin grafiği. (b) ÇDR hata grafiği.

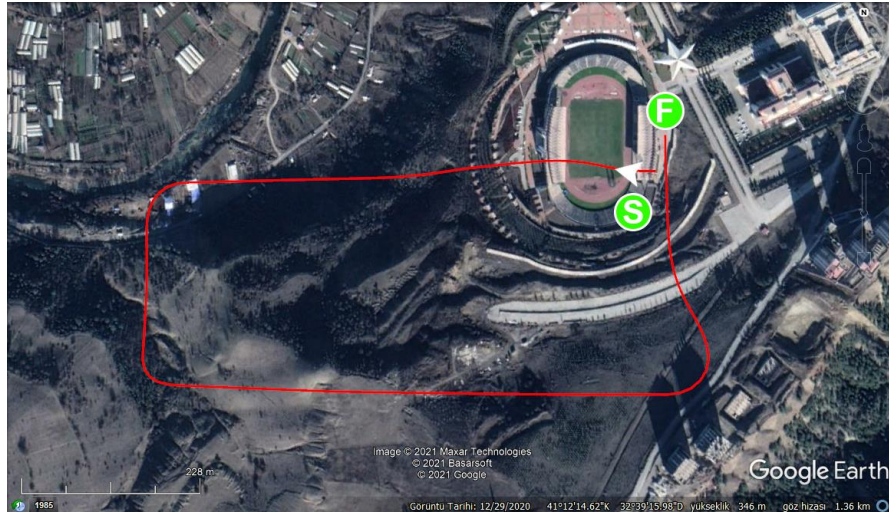
### 8.1.2. Veri Örneklem Adeti Optimizasyonu

Ham veri setinin oluşturulması için 30 farklı konumda gerçekleştirilen uçuşlara ait verilerden toplam 35102 adet örneklemin, uçuş sırasına göre birbiri üzerine eklenerek toplam 30 farklı veri seti oluşturulmuştur. Veri setlerinin algoritma performanslarına göre karşılaştırılması ile deneyler için kullanılacak örneklem adeti tespit edilmeye çalışılmıştır.

Algoritma performanslarının ölçümü için bir önceki çalışmada rastgele birbirinden bağımsız değişkenler kullanılmış olmasına karşın bu çalışmada veri setinde kullanılan uçuşların haricinde iki farklı uçuş gerçekleştirilerek, bu uçuşların tahmin sonuçları değerlendirilmiştir. Şekil 8.2’de uçuşlara ait seyrüsefer güzergahları gösterilmiştir.



(a)



(b)

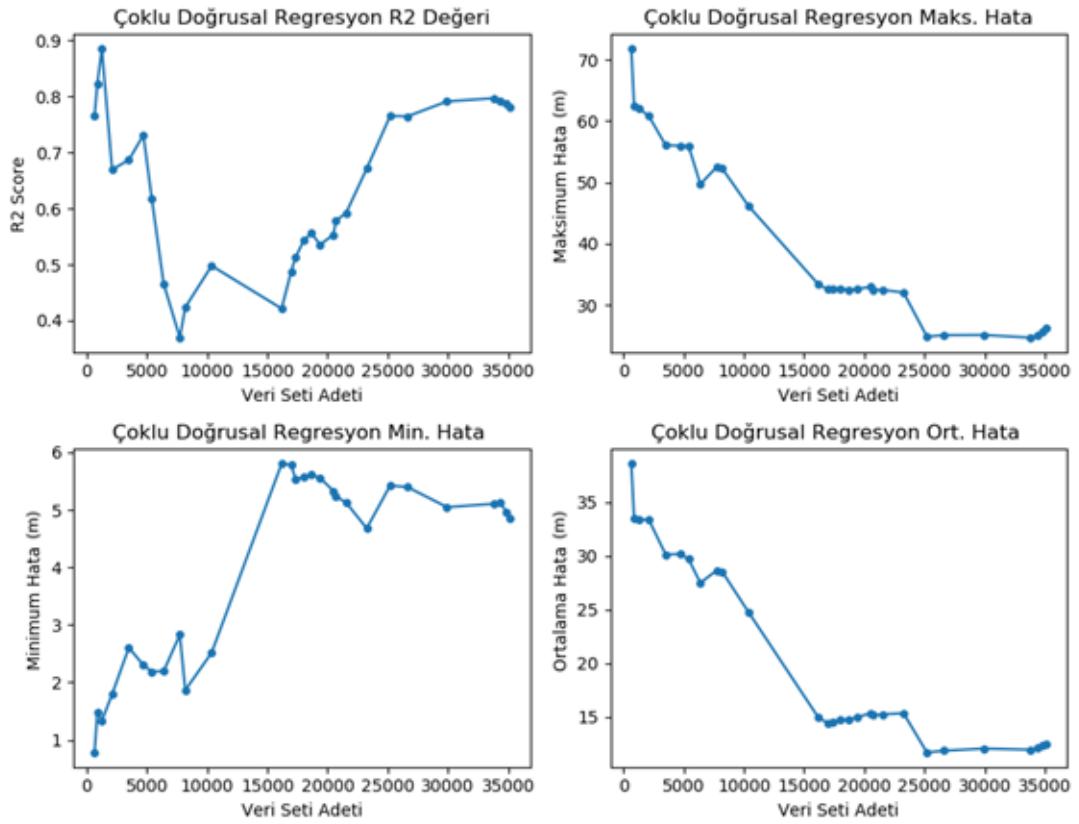
Şekil 8.2 (a) Doğrusal uçuş güzergahı. (b) Geometrik uçuş güzergahı.

### 8.1.2.1.ÇDR İçin Veri Seti Örneklem Adeti Optimizasyonu Analizi

Çoklu Doğrusal Regresyon için veri seti büyüklüğünün optimizasyonu, oluşturulan veri setleri ile Doğrusal Uçuş Güzergahı  $R^2$  Değerleri ve Hata değerleri Şekil 8.3’de gösterilmiştir. Grafikler incelendiğinde  $R^2$  değerinin veri seti adetlerindeki gösterdiği performans, veri seti büyüklüğü 5.000’den küçükken yüksek seyretmektedir. Veri seti büyüdükçe  $R^2$  başarı oranı yükseliyor ve 25.000 adet örneklemden sonra kararlı hale ulaştığı görülmektedir.

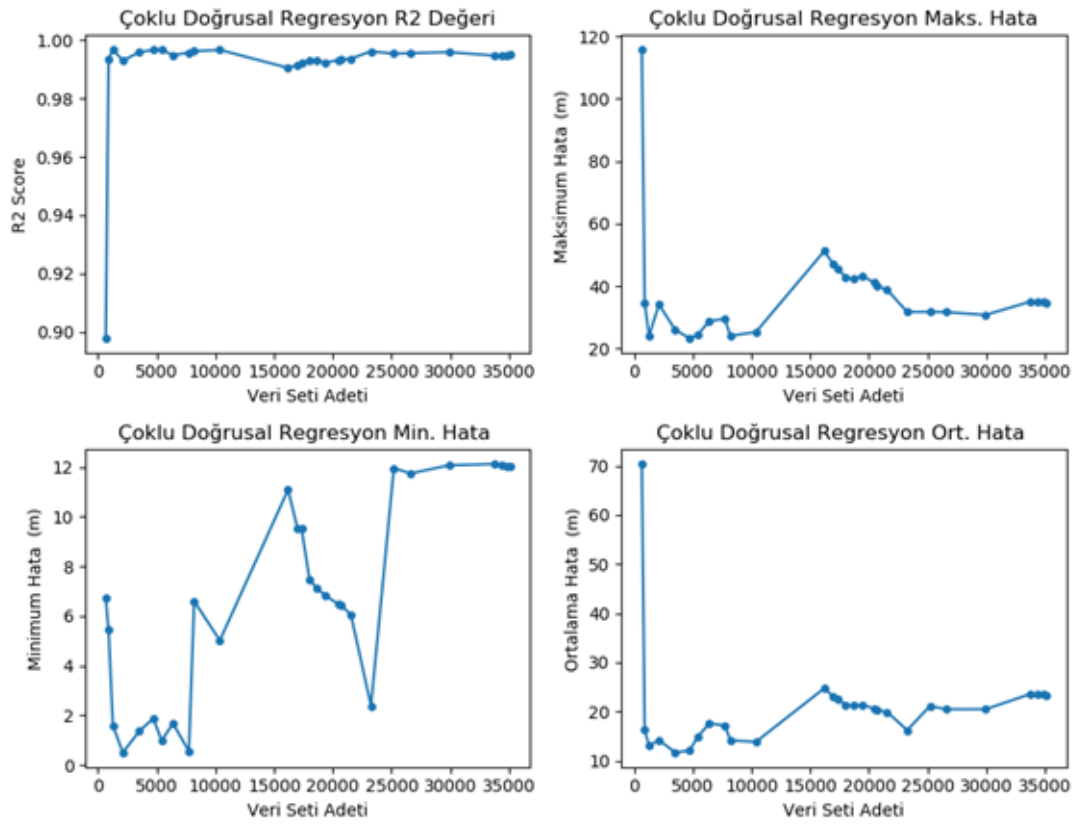
Geometrik uçuş güzergahına ait  $R^2$  Değerleri ve Hata değerleri Şekil 8.4'te gösterildiği gibidir. Sonuçlar incelendiğinde doğrusal uçuş güzergâh sonuçlarından oldukça farklı olduğu göze çarpmaktadır.  $R^2$  değerinin ilk veri setlerinden itibaren yüksek olduğu, orta bölgelerde azalmasına karşın yeniden yükseldiği, hata değerlerinin ortalamasının ise doğrusal uçuş güzergahına göre yüksek olduğu gözlemlenmiştir.

Maksimum  $R^2$  başarı ve Minimum Ortalama Hata gösterdiği veri setlerinin uçuş güzergahları üzerindeki görünümü Şekil 8.5'te gösterilmiştir.




Şekil 8.3 Doğrusal uçuş güzergâhı ÇDR konum tahmin sonuçları.

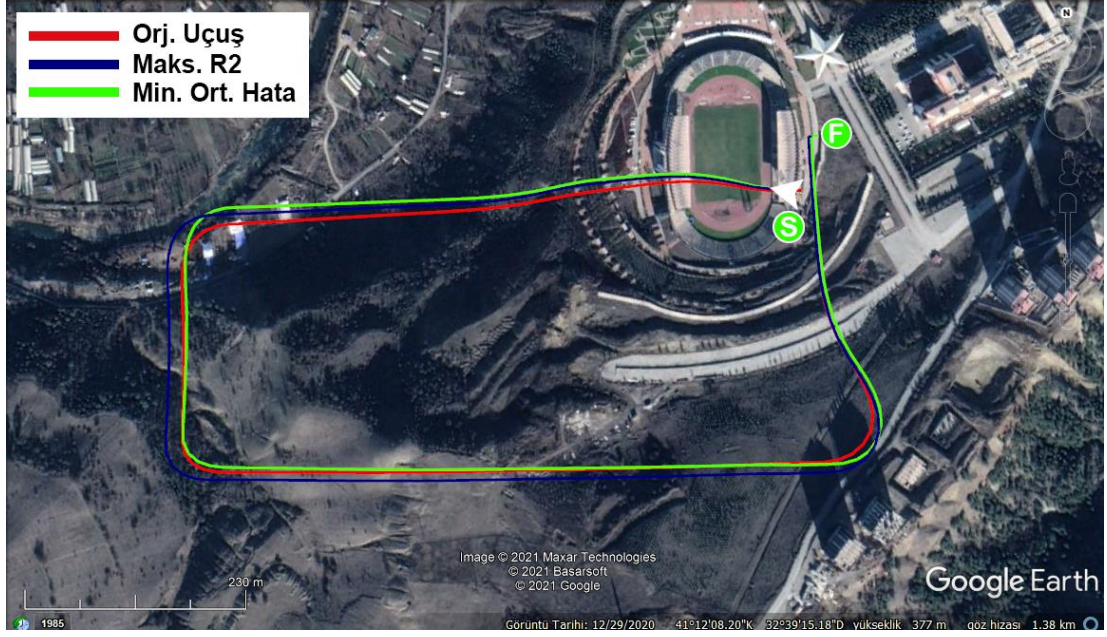




Şekil 8.4 Geometrik uçuş güzergâhı ÇDR konum tahmin sonuçları.



(a)



(b)

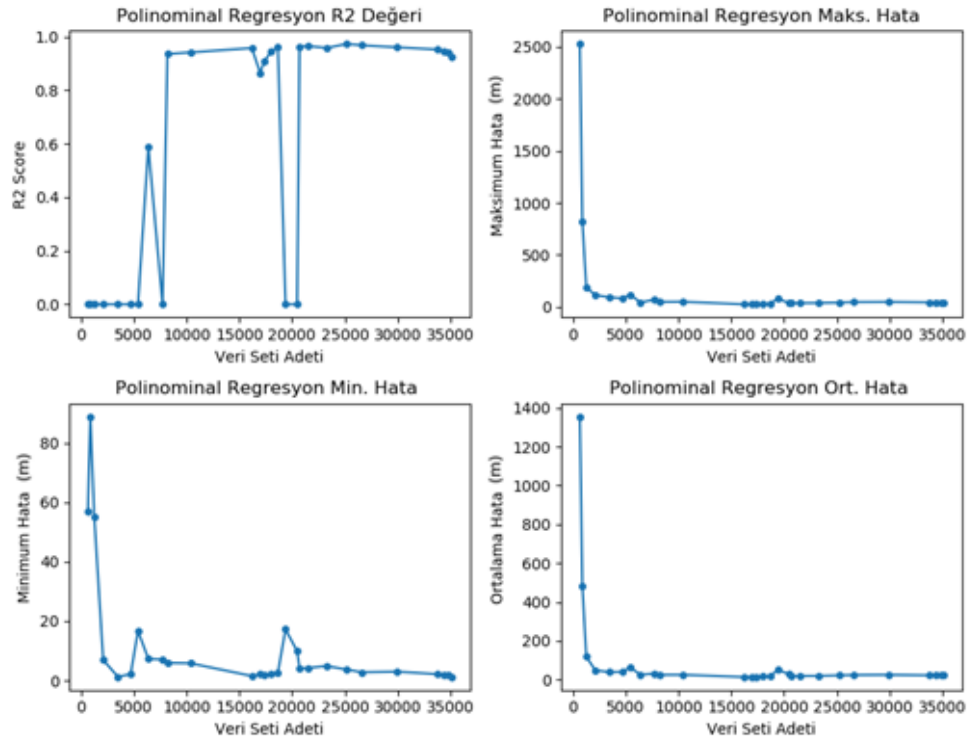
Şekil 8.5 (a) ÇDR, doğrusal uçuş güzergâh tahmin sonuçları. (b) ÇDR, geometrik uçuş güzergâh tahmin sonuçları.

### 8.1.2.2. PR Veri Seti Örneklem Adeti Optimizasyonu Analizi

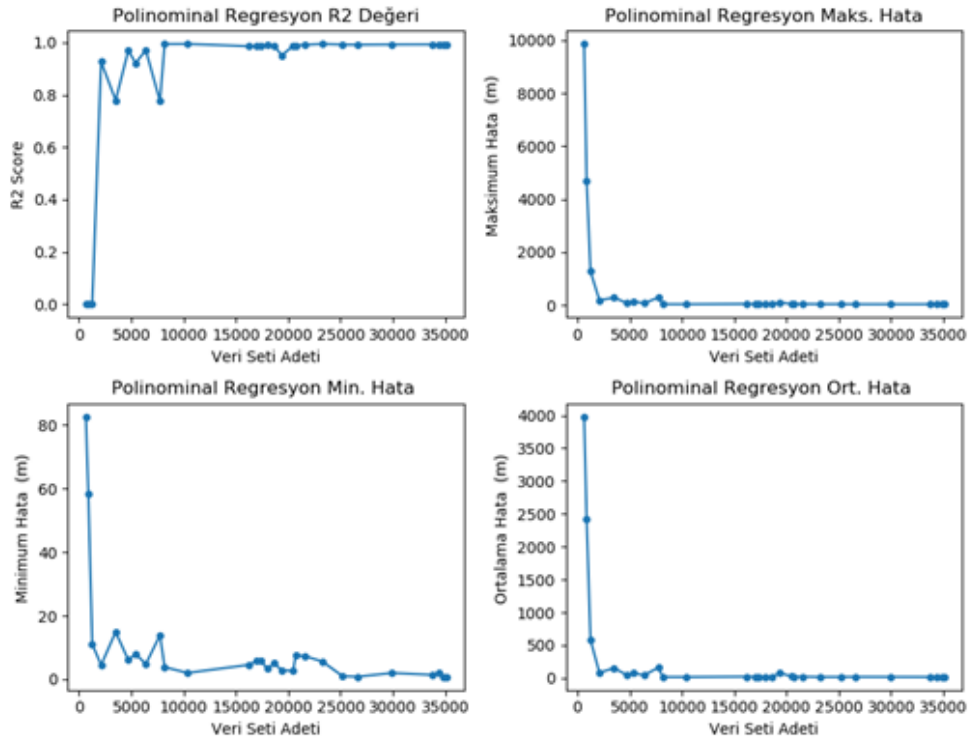
Polinomial Regresyon algoritması veri seti büyüklüğü optimizasyonu için gerçekleştirilen deneylerin sonuçları Şekil 8.6 ve Şekil 8.7’de gösterilmiştir.

Sonuçlar incelendiğinde iki uçuş arasında  $R^2$  değerinin değişkenlik gösterdiği gözlemlenmektedir. Veri seti büyüklüğü ile uçuşların doğrusal ve geometrik olmaları Polinomial Regresyon algoritmasında başarı oranlarını oldukça etkilediği gözükmektedir. Hata değerlerinin ise oransal olarak aynı olduğunu söylemek mümkündür.


Deneylere ait Maksimum  $R^2$  başarı ve Minimum Ortalama Hata gösterdiği veri setlerinin uçuş güzergahları üzerindeki görünümü Şekil 8.8’te gösterilmiştir.



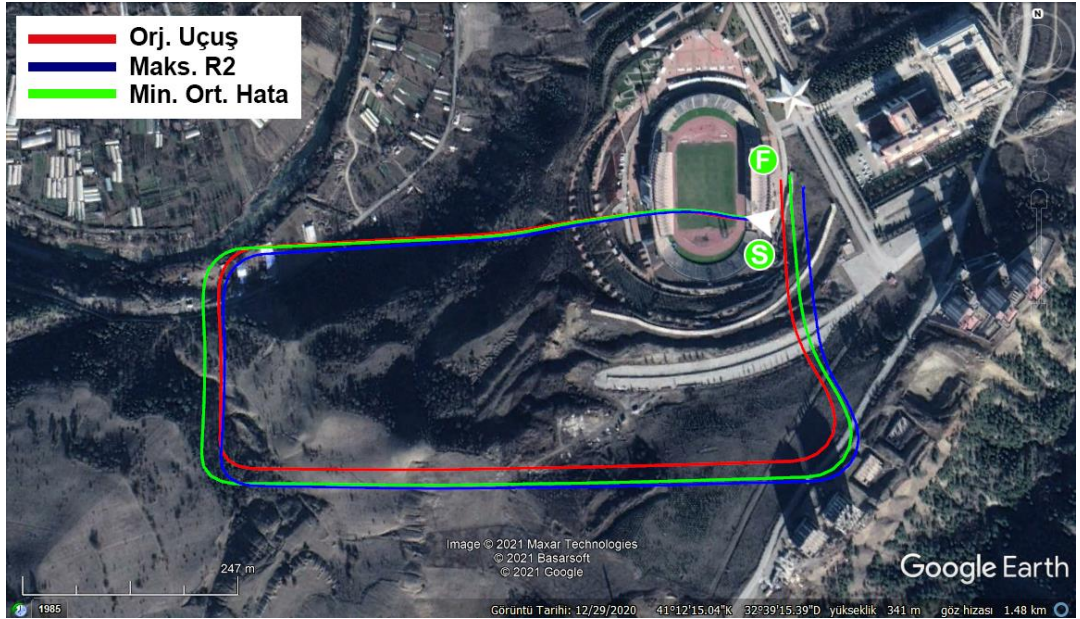
Şekil 8.6 Doğrusal uçuş güzergâhı PR konum tahmin sonuçları.



Şekil 8.7 Geometrik uçuş güzergâhı PR konum tahmin sonuçları.



(a)



(b)

Şekil 8.8 PR, doğrusal uçuş güzergâh tahmin sonuçları. (b) PR, geometrik uçuş güzergâh tahmin sonuçları.

### 8.1.2.3. Optimizasyon Sonuç Değerlendirmesi

Veri seti örneklem adeti optimizasyonu için yapılan deneylere ait algoritmaların performans grafikleri incelendiğinde uçuş güzergahlarına göre deney setlerinden alınan performansın değişiklik gösterdiği görülmektedir. Bu sebepten dolayı veri setinin optimizasyonu için sabit bir örneklem sayısına sahip veri seti belirlemenin performans açısından kötü sonuçlar doğuracağı kanaatine varılmıştır.

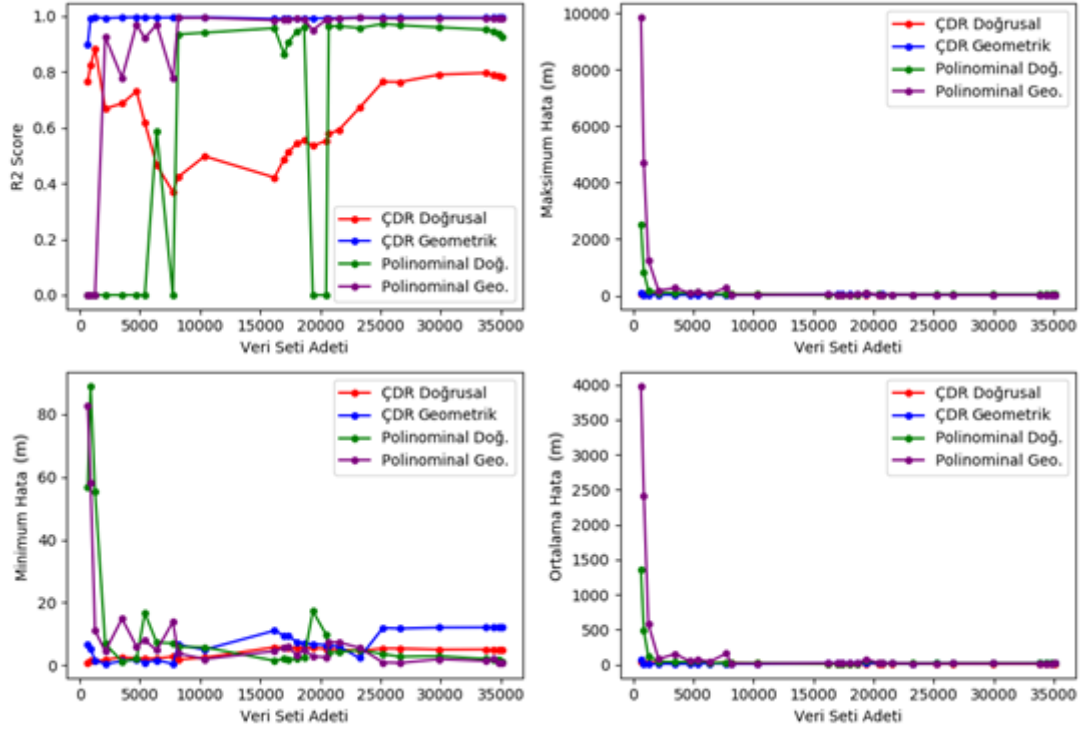
Sistem konum tahmini yaparken mevcut tüm veri setleri ile birer model geliştirilip, modellerin  $R^2$  başarı ve minimum ortalama hata değerlerine sahip konum bilgilerinin kullanılması başarılı sonuçların elde edilmesine olanak sağlayacağı düşünülmektedir.

Çoklu Doğrusal Regresyon ve Polinomial Regresyon algoritmaları ile gerçekleştirilen toplam dört deneyin maksimum  $R^2$  ve Minimum ortalama hata değerleri Çizelge 8.2’de, deneylere ait grafikler ise Şekil 8.9’de gösterilmiştir. Grafikler incelendiğinde Polinomial Regresyon ile Doğrusal uçuş deneyinde örneklemelerde  $R^2$  değerinin bir anda sıfıra düştüğü gözlenmektedir. Bunun sebebi  $R^2$  performansının eksi değerli çıktığı için grafiğin görünürlüğünü etkilemesinden dolayı sıfıra eşitlenmiş olmasıdır.  $R^2$  değerindeki bu ani düşüşe sebep olan etken Bölüm 5’de açıklanmıştır.

Sonuç olarak, grafikler incelendiğinde 5.000 Örneklem adedinin altında kalan veri setlerinin performanslarında kararlılık gözlemlenmediğinden dolayı, güç kullanımını azaltmak için kaldırılması ve geri kalan setler ile deneylerin yapılması performans açısından uygun görülmüştür.

Çizelge 8.2 Örneklem adeti optimizasyonu performans değerleri.

Algoritma	Doğrusal Uçuş		Geometrik Uçuş	
	Maks. $R^2$ Değeri	Min. Ort. Hata (m)	Maks. $R^2$ Değeri	Min. Ort. Hata (m)
Çoklu D.R.	0,8847	11,7072	0,9966	11,6699
Polinom.R.	0,9728	13,8901	0,9945	16,7309



Şekil 8.9 ÇDR ve PR konum tahmin deneyi sonuçları.

### 8.1.3. Bağımsız Değişken Optimizasyonu

Oluşturulan veri setinde 13 bağımsız, 2 adet bağımlı değişken bulunmaktadır (Bkz. Çizelge 7.1). Bu bağımsız değişkenler tahminleme sürecinde her zaman olumlu etki yapmayabiliyorlar. Aralarındaki korelasyona göre olumlu ya da olumsuz etki yaptığı gözlemlenerek, optimizasyon yapılabilmektedir.

Veri boyutu optimize edilen veri setine, Bölüm 5'te anlatılan geri eleme yöntemi ile performansın artırılması için veri optimizasyonu sağlanmıştır. Geri eleme yöntemi için yapılan analiz sonuçları Çizelge 8.3'te gösterilmiştir.

Sonuçlar incelendiğinde, P-value değerinin 0.05'in üzerinde olduğu değişkenler dikkat çekmektedir. Tahmin sürecinde değişkenlerin olumsuz etki oluşturmaması için P-value değerinin sıfıra yakın olması beklenmektedir, sıfırdan büyük P-value değerlerine sahip değişkenler tahminleme sürecine olumsuz etki yapabilmektedir.

P-value değerinin 0.05'in üzerinde olan irtifa bilgisi "alt" ve "alt\_rel" değişkenleri veri setinden çıkartılmıştır.


P-value değerine göre yapılan optimizasyona ek olarak, deneme ve yanılma yöntemi ile de olumsuz etki yapan anlık y eksenli hız bilgisi "vy" değişkeni de veri setinden kaldırılarak veri seti optimizasyonu tamamlanmıştır. Algoritmaların  $R^2$  başarı değerleri ölçülmüştür. Ölçüm değerleri Çizelge 8.4'te, sonuçlara ait grafikler ise Şekil 8.10'da gösterilmiştir. Değerler incelendiğinde tahminleme başarı oranlarının arttığı görülmektedir.

Çizelge 8.3 Veri seti değişkenlerinin korelasyon değerleri.

Değişken	P-value – 1	P-value – 2
lat	0.000	0.000
lon	0.000	<b>0.009</b>
alt	0.000	<b>0.458</b>
alt_rel	<b>0.008</b>	<b>0.229</b>
airspeed	0.000	<b>0.001</b>
groundspeed	0.000	<b>0.015</b>
vx	0.000	0.000
vy	0.000	0.000
vz	0.000	0.000
roll	0.000	0.000
pitch	0.000	0.000
yaw	<b>0.021</b>	0.000
heading	0.000	<b>0.001</b>

Çizelge 8.4 Bağımsız değişken optimizasyonu sonrası performans değerleri.

Algoritma	Doğrusal Uçuş		Geometrik Uçuş	
	Maks. R <sup>2</sup> Değeri (Eski)	Maks. R <sup>2</sup> Değeri (Yeni)	Maks. R <sup>2</sup> Değeri (Eski)	Maks. R <sup>2</sup> Değeri (Yeni)
Çoklu D.R.	0,8847	0,9888	0,9966	0,9981
Polinom.R.	0,9728	0,9771	0,9945	0,9991



Şekil 8.10 ÇDR ve PR konum tahmin deneyi sonuçları.

## 8.2. KONUM KESTİRİM DENEYİ

Simülasyon ortamında gerçekleştirilen uçuşların telemetri verilerinden oluşturulan, makine öğrenimi algoritmalarının eğitildiği veri setlerinin, performans açısından



optimizasyonları tamamlanarak, tam bir uçuş seyrüseferinin tahmini için hazır duruma getirilmiştir.

Karabük Üniversitesi Demirçelik Kampüsü alanı üzerinde gerçekleştirilen tam bir test uçuşunun, eğitilen makine öğrenmesi modelleri ile konum tahmin uygulaması yapılmıştır.

Deneyde tahmin edilecek test uçuşunun güzergahı Şekil 8.11’da gösterilmiştir. Deney uçuşu toplam 1280 metre, maksimum 50 metre irtifada ortalama 15m/s hızda gerçekleşmiştir.



Şekil 8.11 KBÜ kampüsü üzerindeki uçuş güzergahı.

### 8.2.1. Çoklu Doğrusal Regresyon İle Konum Kestirimi

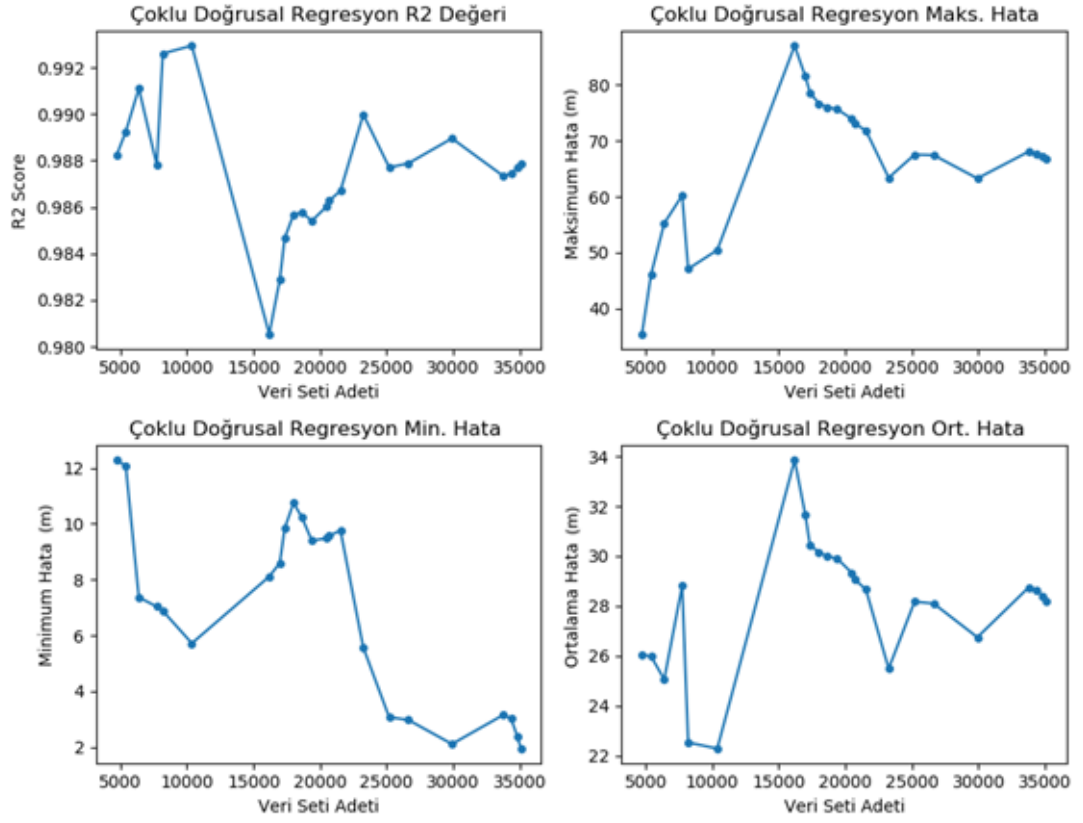
Makine öğreniminin en temel algoritmalarından olan doğrusal regresyon modeline ait Çoklu Doğrusal Regresyon (ÇDR), birçok probleme optimum sonuçlar üretebilmektedir. Deney öncesinde yapılan ön çalışmalarda da görüldüğü üzere, birinci dereceden matematiksel model olmasına rağmen oldukça başarılı sonuçlar

üretmektedir. Bu özelliğinden dolayı birçok uygulamada ilk olarak kullanılan ve projenin geliştirilmesine öncülük eden algoritmalarıdır.

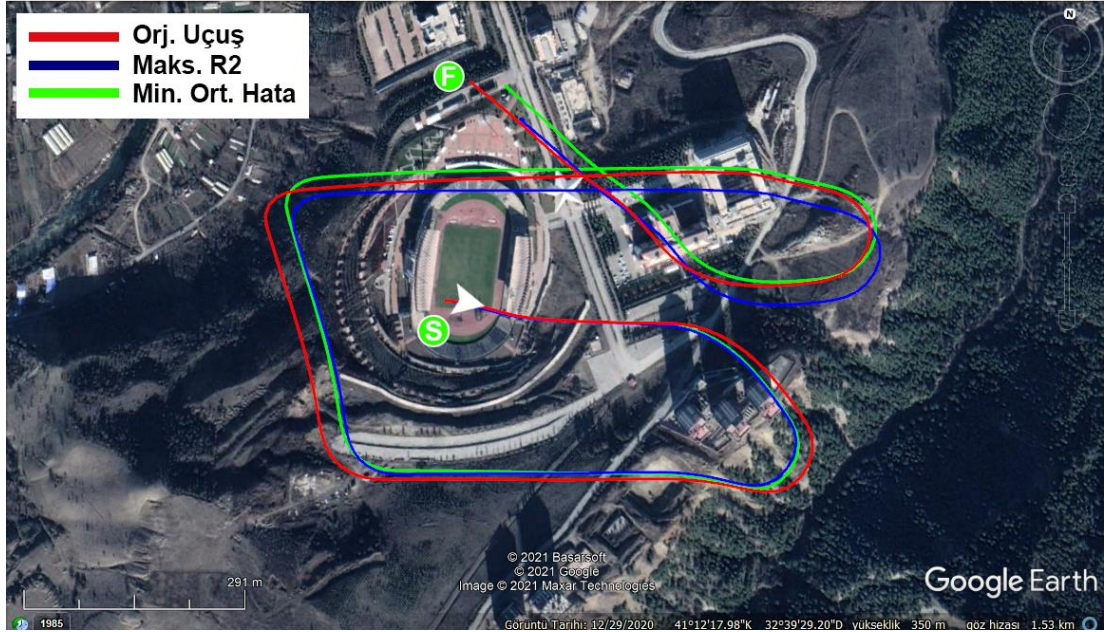
Uçuş deneyinin konum tahmini için ÇDR'e ait sonuç grafikleri Şekil 8.12'de gösterilmiştir. Grafikler incelendiğinde ÇDR'nin maksimum  $R^2$  Değerini 15.000 örneklem altında gerçekleştirdiği, diğer veri setleriyle eğitilen modellerin ise çok kararsız sonuçlar sergilediği görülmektedir.

Hata değerlerine baktığımız zaman minimum hatalarına karşın aynı set içerisinde maksimum hataları ortalama yüksek tutmasına sebep olmuştur. Maksimum  $R^2$  ve minimum ortalama hata değerine sahip tahmin sonuçları uçuş güzergahı üzerinde Şekil 8.13'de gösterilmiştir.

Güzergahlar incelendiğinde minimum ortalama hataya ait güzergahın uçuş boyunca orijinal güzergaha yakın seyrettiği iniş öncesinde uzaklaştığı gözükmektedir. Maksimum  $R^2$  değerine sahip güzergahın, iniş öncesinde sisteme daha çok yaklaştığı ve iniş anında gerçeğe çok yakın sonuçlar verdiği gözlemlenmektedir.



Şekil 8.12 ÇDR konum kestirim sonuçları.



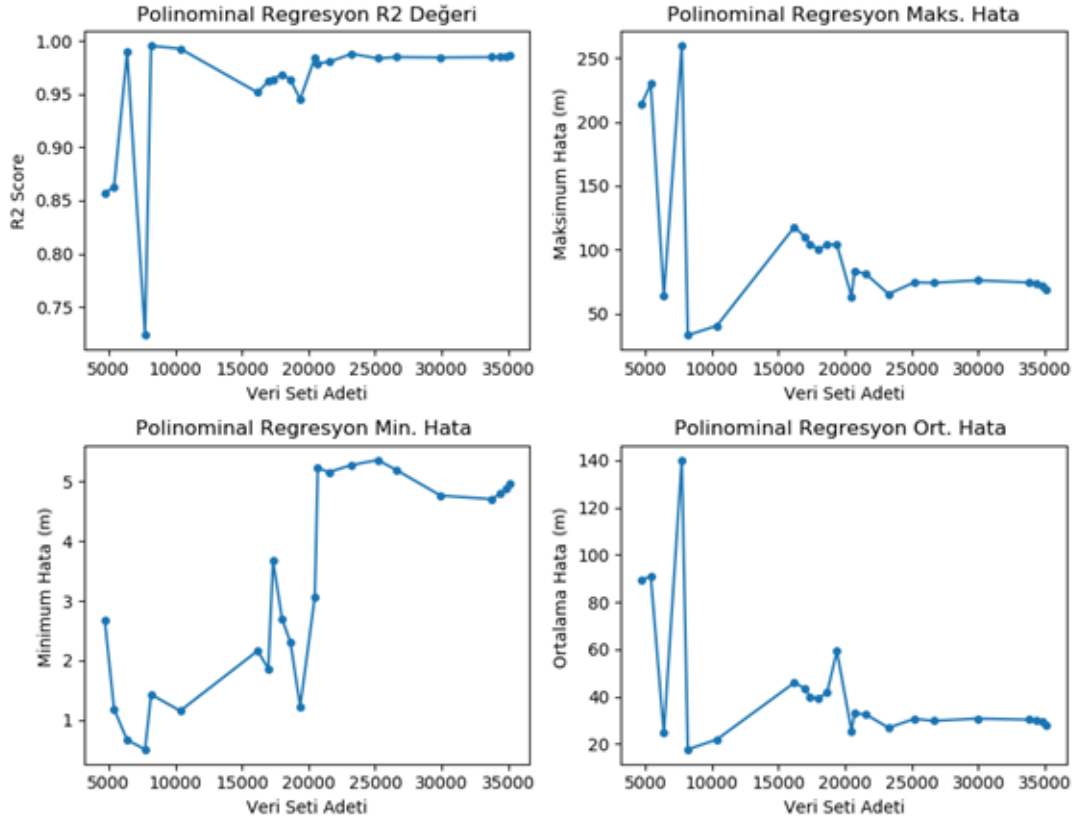
Şekil 8.13 ÇDR maksimum R<sup>2</sup> ve minimum ortalama hata uçuş güzergahları.

### 8.2.2. Polinomial Regresyon İle Konum Kestirimi

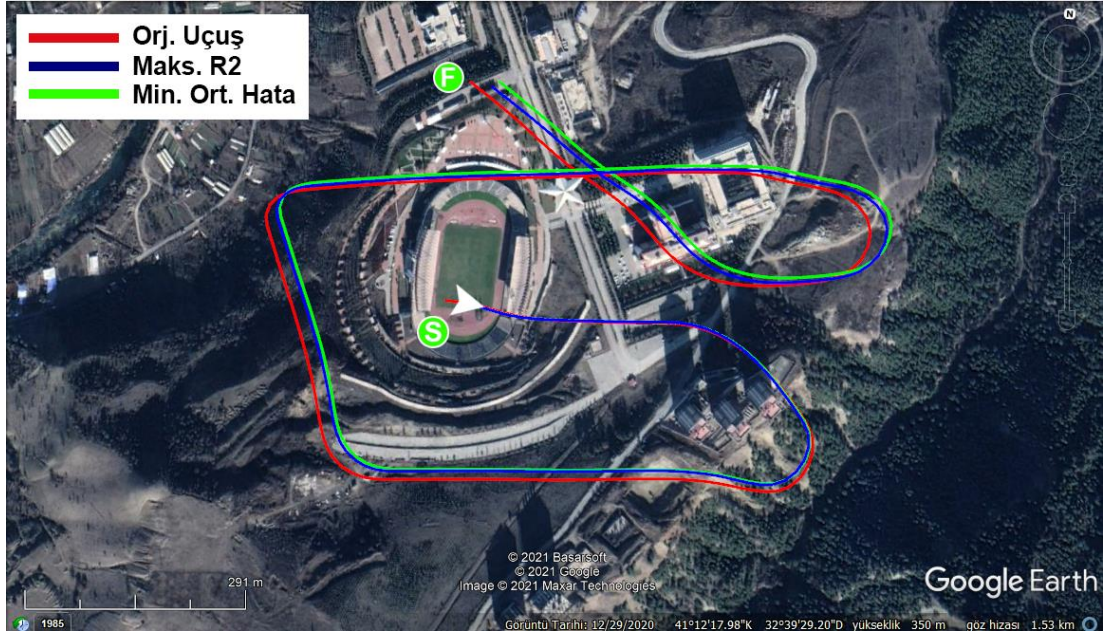
Doğrusal regresyon modeli olan Polinomial Regresyon, veri setinde doğrusal regresyon gibi bir doğru üzerinden değil daha çok eğri üzerinden ilişki kurarak matematiksel modelini iki ve üzeri olarak derecelendirir. Doğrusal olmayan problemlerin çözümünde oldukça başarılı sonuçlar veren bu model makine öğrenimi algoritmalarının en sık kullanılanlarından biridir.

Uçuş deneyine ait Polinomial Regresyon sonuçları Şekil 8.14'te gösterilmiştir. Sonuç grafikleri incelendiğinde 10.000 adet örneklem sonrasındaki eğitilen modellerin  $R^2$  değerlerinin kararlılığı gözlemlenmektedir. Bu kararlılığa karşı minimum hata da performansının düştüğü, maksimum hatanın da aynı oranda düşerek ortalama hatanın dengelendiği görülmektedir.

Polinomial Regresyon konum kestirimi sonuçlarına ait maksimum  $R^2$  ve minimum hataya sahip konum tahminleri Şekil 8.15'te gösterilmiştir. Tahmin güzergahı incelendiğinde maksimum  $R^2$  değerinin orijinal uçuş güzergahına daha yakın seyrettiği görülmektedir.



Şekil 8. 14 PR konum kestirim sonuçları.



Şekil 8. 15 PR maksimum R<sup>2</sup> ve minimum ortalama hata uçuş güzergahları.

### 8.2.3. Konum Kestirim Deęerlendirmesi

Bir önceki başlıkta, yapılan deney uçuşuna ait ÇDR ve Polinomial Regresyon algoritmalarının konum kestirim sonuçları ayrı ayrı incelenmiş gösterdikleri performans değerlendirmiştir. Konum kestirim performansı açısından hangi algoritmanın daha iyi olduğu konusunda incelemeyi Şekil 8.16'de ki ortak grafikler inceleyerek belirlenmeye çalışılmıştır.


İki algoritmanın gösterdiği  $R^2$  başarı değerine bakıldığında, ÇDR tüm modellerde neredeyse kararlı bir davranış sergileyerek grafiğin ortalarında bulunurken, Polinomial Regresyon, maksimum  $R^2$  değerini gördükten sonra inişli çıkışlı bir grafik sergilemiştir.

Hata değerlerinde en iyi sonuçlar ÇDR'ye ait olmasına karşın modellerden minimum ortalama hatayı Polinomial Regresyon sergileyerek en iyi performansı gösterdiği görülmektedir.


Bu uçuşlar ayrı ayrı incelediğinde maksimum  $R^2$  değerlikli konum kestirime ait güzergahların en iyi sonuç gösterdiği tespit edilmişti. Deney uçuşu ve algoritmala tahminleriyle yapılan, maksimum  $R^2$  değerlikli konum kestirime ait uçuş güzergahlarının harita görünümüne (Şekil 8.17) bakıldığında, iki algoritmanın performanslarının birbirine yakın seyrettiği görülmektedir. Fakat maksimum  $R^2$  değeri ve minimum ortalama hataya sahip olan Polinomial Regresyonun orijinal deney uçuş güzergahına çok daha yakın seyrettiği çok daha belirgin olarak gözükmektedir.

Konum kestirime ait enlem ve boylam bilgilerinin, orijinal uçuş bilgilerine kıyaslaması Şekil 8.18'de gösterildiği gibidir. Algoritmalar bilgilerin kestiriminde gösterdiği performans oldukça gerçeğe yakın olarak gözlemlenmiştir.

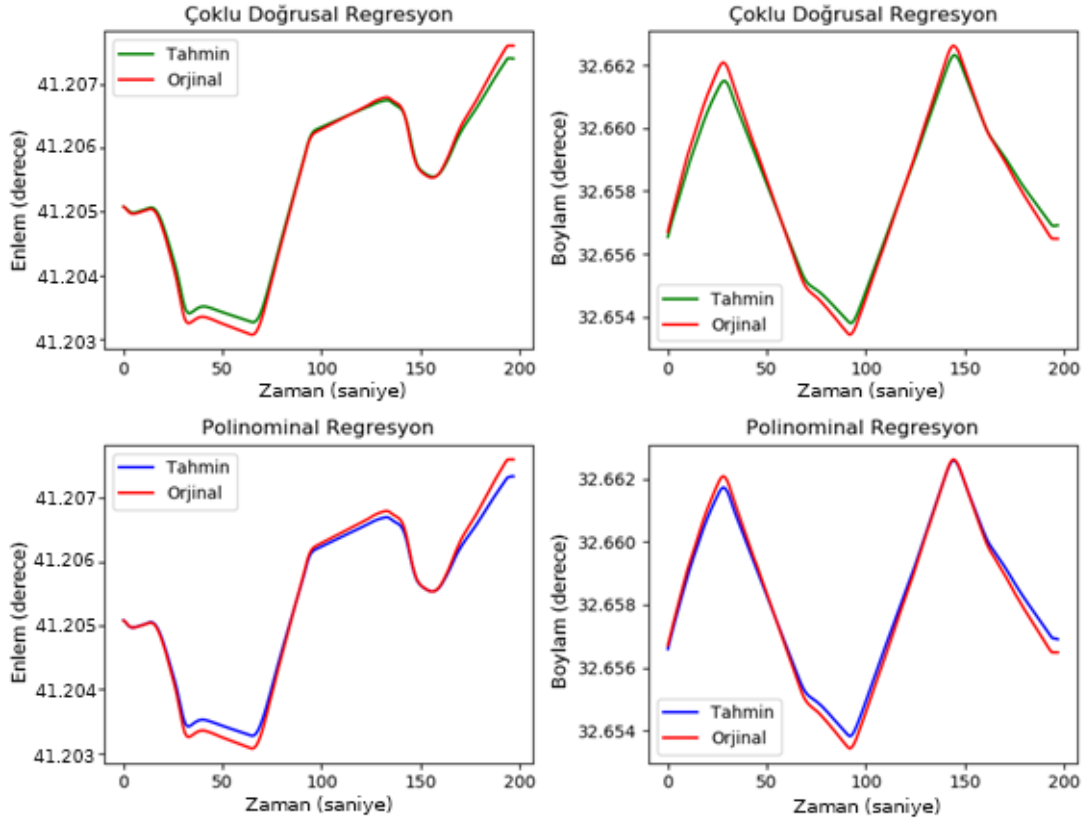
Bu verilerin sayısal değerlikleri Çizelge 8.5'de gösterilmiştir.



Şekil 8. 16 Deney uçuşuna ait ÇDR ve PR algoritmalarının performans grafikleri.



Şekil 8. 17 ÇDR ve PR'e ait konum kestirimi uçuş güzergahları.



Şekil 8.18 ÇDR ve PR'e ait enlem, boylam kestirim grafikleri.

Çizelge 8.5 Konum kestirimi performans değerleri.

Değer	Çoklu Doğrusal Regresyon	Polinominal Regresyon
Maksimum $R^2$	0.9952	0.9978
Maksimum Hata (m)	36.7948	18.3341
Minimum Hata (m)	0.1577	0.6432
Ortalama Hata (m)	16.9542	11.9391
$R^2$ (Enlem)	0.9939	0.9918
$R^2$ (Boylam)	0.9876	0.9899



## BÖLÜM 9

### SONUÇLAR

İnsansız hava araçlarının güvenli bir seyrüsefer ve görevlerini tamamlayabilmeleri gerekli kritik bilgilerden biri de coğrafi konum bilgisidir. Bu bilgiyi çeşitli sensörler ve sistemler vasıtası ile dolaylı veya doğrudan elde etmek mümkündür. Havacılık tarihi boyunca çeşitli yöntemlerle elde edilen bu bilgiler günümüzde ağırlıklı olarak GNSS (Küresel Navigasyon Uydu Sistemi) vasıtası ile gerçekleştirilmektedir.

GNSS, gelişmiş ülkelerin uydu ve sistemlerinin bulunduğu bir dış kaynaklı bir sistemdir. Hava araçları tarafında alıcıları bulunan bu sistemler, uydu referanslarına göre hesap edilerek konum bilgisini dünya üzerine düşük bir frekansta yayarlar. Bu düşük frekans çoğu zaman dış etkenlerden dolayı kesintiye uğrar ve bilgi üretmezler. Bu durumlarda dahili sensörler kullanılarak hava aracının konum kestirimi yapılmaktadır. Bu tür uygulamalara sensör füzyonu uygulamaları denilmektedir.

Sensör füzyonu, aracın içerisinde bulunan seyrüsefer ile alakalı, aracın duruşu, hızı gibi bilgileri üreten sensörlerin harmanlanması ile anlamlı bilgilerin oluşturulması işlemidir. Literatür de bu işlem sırasında birçok metot uygulandığı görülmektedir. Bu metotlar arasında kestirim algoritmaları adı altında popülerleşmiş matematiksel modellerde bulunmaktadır.

Bu çalışmada, konum kestirimi için uygulanana bu metotlara bir alternatif olarak günümüzde popülerliği her geçen gün artan jenerik adı ile Yapay Zekâ olan Makine Öğrenmesi metodu kullanılmış olup sonuçları değerlendirilmiştir.

Çalışma sırasında uygulamalar yüksek seviye programlama dili olan Python ile geliştirilmiş olup, yine bu dil için oluşturulmuş Makine Öğrenimi kütüphanesi olan

Scikit-Learn kütüphanesi ile makine öğrenimi modelleri oluşturulup eğitilmiştir. Bu eğitimlerin yapılmasına büyük kolaylık sağlayan Python için bilimsel geliştirme ortamı sağlayan Spyder Python IDE ortamı, uygulamaya veri seti sağlayan simülasyon ortamı için kurulan sanal makine üzerinde Linux işletim sistemi ve içerisinde ki ROS, Gazebo, PX4 Firmware, Drone-kit; Windows 10 64Bit Intel(R) Core(TM) i5-8250U CPU @ 1.60GHz 1.80 GHz, 12 GB RAM özellikli bir bilgisayar üzerinde gerçekleştirilmiştir.

Yapılan çalışmalarda öncelikle seyrüsefer ile alakalı telemetri verilerinin belirlenmesi ve veri seti için yapılan uçuşlarda bu verilerin kaydedilmesi işlemi gerçekleştirilmiştir. Akabinde bu verilerin bir ön işleme ile performansları değerlendirilmiş olup, optimizasyonları gerçekleştirilerek deney setine hazırlıkları yapılmıştır.

Makine öğrenimi konusunda en temel algoritma modeli olan Doğrusal Regresyon modelin ait Çoklu Doğrusal Regresyon ve Polinomial Regresyon algoritmalarının performanslarının detaylı incelemeleri yapılmış olup, uygulamanın bir sistemde nasıl çalıştığına dair bulgular elde edilmiştir.

Elde edilen bulgular ve grafikler incelendiğinde bir insansız hava araçları için yapılan bu konum tahmininde makine öğrenimi algoritmalarının başarılarının oldukça kabul edilebilir olduğu görülmektedir. Yapay zekâ çalışmalarının büyük bir çoğunluğunda %90 başarı problemlerin çözüldü olarak sayıldığı düşünüldüğünde, matematiksel modeli oluşturulabilen, çok fazla değişkeni olmayan konum tahmini problemi için %98'lik sonuçlar kabul edilebilir düzeydedir.

Bu çalışmanın sonucu olarak; konum kestirimi problemine karşı gösterdiği başarılı sonuçlar ile Makine Öğrenimi, kullanılacak farklı algoritmalar, farklı veri setleri ile optimizasyonu yapılabilecek gelecekte birçok probleme çözüm olabilecek bir metot olduğu söylenebilmektedir.

Yapılan bu çalışma genel hatları ile insansız hava araçları için konum kestirimi problemine, hava aracı içi dahili sensör verileri kullanılarak, makine öğrenimi destekli sensör füzyonu olarak yeni bir metot sunmuştur.

## KAYNAKLAR

1. Rip, M. R., J. M. Hasik, and N. I. Press, *The Precision Revolution: GPS and the Future of Aerial Warfare*. *Naval Institute Press*, 2002. [Online]. Available: <https://books.google.com.tr/books?id=mB9W3H90KDUC>
2. noaa.gov, “GPS & Selective Availability Q&A.” Accessed: Apr. 11, 2021. [Online]. Available: [https://web.archive.org/web/20120329111058/http://ngs.woc.noaa.gov/FGC\\_S/info/sans\\_SA/docs/GPS\\_SA\\_Event\\_QAs.pdf](https://web.archive.org/web/20120329111058/http://ngs.woc.noaa.gov/FGC_S/info/sans_SA/docs/GPS_SA_Event_QAs.pdf)
3. Yoo, C. S. and I. K. Ahn, “Low cost GPS/INS sensor fusion system for UAV navigation,” in *AIAA/IEEE Digital Avionics Systems Conference - Proceedings*, 2003, vol. 2. doi: 10.1109/dasc.2003.1245891.
4. Hide, C., T. Moore, and M. Smith, “Adaptive Kalman filtering for low-cost INS/GPS,” *J. Navig.*, vol. 56, no. 1, pp. 143–152, Jan. 2003, doi: 10.1017/S0373463302002151.
5. Wang, J., M. Garratt, A. Lambert, J. J. Wang, S. Han, and D. Sinclair, “INTEGRATION OF GPS/INS/VISION SENSORS TO NAVIGATE UNMANNED AERIAL VEHICLES.”
6. Jingsen, Z., Z. Wenjie, H. Bo, and W. Yali, “Integrating extreme learning machine with kalman filter to bridge gps outages,” in *2016 3rd International Conference on Information Science and Control Engineering (ICISCE)*, 2016, pp. 420–424.
7. Mostafa, M. M., A. M. Moussa, N. El-Sheimy, and A. B. Sesay, “A smart hybrid vision aided inertial navigation system approach for UAVs in a GNSS denied

- environment,” *Navig. J. Inst. Navig.*, vol. 65, no. 4, pp. 533–547, Dec. 2018, doi: 10.1002/navi.270.
8. Al-Turjman, F., “A novel approach for drones positioning in mission critical applications,” *Trans. Emerg. Telecommun. Technol.*, p. e3603, 2019.
  9. Al-Turjman, F., “Drones Navigation in Mission Critical Applications,” *Drones in IoT-enabled Spaces*, pp. 99–118, 2019.
  10. Atia, M. M., A. Noureldin, and M. Korenberg, “Gaussian process regression approach for bridging GPS outages in integrated navigation systems,” *Electron. Lett.*, vol. 47, no. 1, pp. 52–53, 2011.
  11. Tan, X., J. Wang, S. Jin, and X. Meng, “GA-SVR and pseudo-position-aided GPS/INS integration during GPS outage,” *J. Navig.*, vol. 68, no. 4, pp. 678–696, 2015.
  12. Belhajem, I., Y. Ben Maissa, and A. Tamtaoui, “A hybrid machine learning based low cost approach for real time vehicle position estimation in a smart city,” in *International Symposium on Ubiquitous Networking*, 2016, pp. 559–572.
  13. Jiao, Y., J. J. Hall, and Y. T. Morton, “Performance evaluation of an automatic GPS ionospheric phase scintillation detector using a machine-learning algorithm,” *Navig. J. Inst. Navig.*, vol. 64, no. 3, pp. 391–402, 2017.
  14. Li, J., N. Song, G. Yang, M. Li, and Q. Cai, “Improving positioning accuracy of vehicular navigation system during GPS outages utilizing ensemble learning algorithm,” *Inf. Fusion*, vol. 35, pp. 1–10, 2017.
  15. Abdolkarimi, E. S., G. Abaei, and M. R. Mosavi, “A wavelet-extreme learning machine for low-cost INS/GPS navigation system in high-speed applications,” *Gps Solut.*, vol. 22, no. 1, p. 15, 2018.

16. Belhajem, I., Y. Ben Maissa, and A. Tamtaoui, "Improving low cost sensor based vehicle positioning with Machine Learning," *Control Eng. Pract.*, vol. 74, pp. 168–176, 2018.
17. Wang, D., X. Xu, and Y. Zhu, "A novel hybrid of a fading filter and an extreme learning machine for GPS/INS during GPS outages," *Sensors*, vol. 18, no. 11, p. 3863, 2018.
18. Aslinezhad, M., A. Malekijavan, and P. Abbasi, "ANN-assisted robust GPS/INS information fusion to bridge GPS outage," *EURASIP J. Wirel. Commun. Netw.*, vol. 2020, no. 1, pp. 1–18, 2020.
19. Beard, R. W. and T. W. McLain, *Small unmanned aircraft: Theory and practice*. **Princeton university press**, 2012.
20. Kayton, M. and W. R. Fried, *Avionics Navigation Systems*. **Wiley**, 1997. [Online]. Available: <https://books.google.com.tr/books?id=1KLTUWLz8jcC>
21. Aerial Navigation, s.8, FAA Aviation News: Vol.2, No:12, A. 1964, "No Title".
22. Özdemir, U., Radyo Seyrüsefer Yardımcıları, s.4-35 DHMİ Genel Müdürlüğü, 2003., "No Title".
23. Taylor, R. L., *Instrument Flying*. **McGraw Hill Professional**, 1997.
24. Connes, K. The Loran, GPS & NAV/COMM Guide, Butterfield Press, 1998., "No Title".
25. Kaltenhauser, H. Radio Navigation, Institute of Air Navigation Services, EUROCONTROL, 1996., "No Title".
26. Eschenbach, R., "GPS applications in general aviation," *Glob. Position. Syst. theory Appl.*, vol. 2, pp. 375–395, 1997.

27. Maybeck, P. S., *Stochastic Models, Estimation and Control: A Series of Monographs and Textbooks. 1. Acad. Press*, 1979. [Online]. Available: <https://books.google.com.tr/books?id=7UXzzQEACAAJ>
28. KAY, M. S., “2018 TÜBİTAK ULUSLARARASI İNSANSIZ HAVA ARAÇLARI YARIŞMASI SENSÖRLER VE KESTİRİCİLER,” 2018. [https://web.archive.org/web/20180508070928/http://uavturkey.tubitak.gov.tr/assets/2018\\_iha\\_egitim\\_suat\\_kay.pdf](https://web.archive.org/web/20180508070928/http://uavturkey.tubitak.gov.tr/assets/2018_iha_egitim_suat_kay.pdf) (accessed Apr. 28, 2021).
29. BİROĞUL, S., Y. SÖNMEZ, and U. GÜVENÇ, “Veri füzyonuna genel bir bakış,” *Politek. Derg.*, vol. 10, no. 3, 2007.
30. Brooks, R. R. and S. S. Iyengar, *Multi-sensor fusion: fundamentals and applications with software. Prentice-Hall, Inc.*, 1998.
31. Mahler, R. P. S. and H. Nguyen, “Mathematics of Data Fusion.” Kluwer, 1997.
32. Kessler, O., K. Askin, and N. Beck, “Functional Description of the Data Fusion Process, technical report for the Office of Naval Technology Data Fusion Development Strategy,” *Nav. Air Dev. Cent.*, 1991.
33. Hall, D. L. and S. A. H. McMullen, *Mathematical techniques in multisensor data fusion. Artech House*, 2004.
34. Kalman, R., “A new approach to linear filtering and prediction problems,” 1960, Accessed: Dec. 27, 2020. [Online]. Available: <https://asmedigitalcollection.asme.org/fluidsengineering/article-abstract/82/1/35/397706>
35. Kalman, R. and R. Bucy, “New results in linear filtering and prediction theory,” 1961, Accessed: Dec. 27, 2020. [Online]. Available: <https://asmedigitalcollection.asme.org/fluidsengineering/article-abstract/83/1/95/426820>

36. Tarin, C., H. Brugger, ... R. M.-... /99. P. of, and undefined 1999, "Low level sensor fusion for autonomous mobile robot navigation," *ieeexplore.ieee.org*, Accessed: Dec. 27, 2020. [Online]. Available: [https://ieeexplore.ieee.org/abstract/document/776031/?casa\\_token=cNoqW-99X0oAAAAA:vjy4rqCo0pGB\\_dZm0r0d20bMIJtflr9RkvDubYsvB\\_nyKxOCaaWl7ZnPlImHIYfRRUhdwUSIfA](https://ieeexplore.ieee.org/abstract/document/776031/?casa_token=cNoqW-99X0oAAAAA:vjy4rqCo0pGB_dZm0r0d20bMIJtflr9RkvDubYsvB_nyKxOCaaWl7ZnPlImHIYfRRUhdwUSIfA)
37. Welch, G. and G. Bishop, "An introduction to the Kalman filter," 1995.
38. Wenzel, L., "Kalman-filter," *Elektron. 8, 11, 13*), 2000.
39. Valavanis, K. P., "Advances in unmanned aerial vehicles: state of the art and the road to autonomy," 2008.
40. "History of Computers." <https://web.archive.org/web/20200102191604/http://www.cs.uah.edu/~rcoleman/Common/History/History.html> (accessed Dec. 29, 2020).
41. "Computer Scientists Wield Artificial Intelligence to Battle Tax Evasion - The New York Times." <https://www.nytimes.com/2015/10/10/business/computer-scientists-wield-artificial-intelligence-to-battle-tax-evasion.html> (accessed Dec. 29, 2020).
42. "Blaise Pascal | Biography, Facts, & Inventions | Britannica." <https://www.britannica.com/biography/Blaise-Pascal> (accessed Dec. 29, 2020).
43. "Neural Networks - History." <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history1.html> (accessed Dec. 29, 2020).
44. "History of Neural Networks." <http://www2.psych.utoronto.ca/users/reingold/courses/ai/cache/neural4.html>

(accessed Dec. 29, 2020).

45. “Explore the history of machine learning.” <https://cloud.withgoogle.com/build/data-analytics/explore-history-machine-learning/> (accessed Dec. 29, 2020).
46. Ivakhnenko, A. and V. Lapa, “CYBERNETIC PREDICTING DEVICES,” 1966, Accessed: Dec. 29, 2020. [Online]. Available: <https://apps.dtic.mil/sti/citations/AD0654237>
47. Dettmers, T., “Deep learning in a nutshell: history and training parallel forall.” 2015.
48. Fukushima, K., “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position,” *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202, Apr. 1980, doi: 10.1007/BF00344251.
49. LeCun, Y. *et al.*, “Backpropagation Applied to Handwritten Zip Code Recognition,” *Neural Comput.*, vol. 1, no. 4, pp. 541–551, Dec. 1989, doi: 10.1162/neco.1989.1.4.541.
50. LeCun, Y., B. Boser, and J. S. Denker, “D. henderson, RE Howard, W. hubbard, and LJ Jackel. Handwritten digit recognition with a back-propagation network,” *Neural Inf. Process Syst.*, p. 396, 1989.
51. Hinton, G., P. Dayan, B. Frey, R. N.- Science, and undefined 1995, “The” wake-sleep” algorithm for unsupervised neural networks,” [science.sciencemag.org](https://science.sciencemag.org), Accessed: Dec. 29, 2020. [Online]. Available: <https://science.sciencemag.org/content/268/5214/1158.abstract>
52. Hochreiter, S. and J. Schmidhuber, “Long Short-Term Memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.



53. James, G., D. Witten, T. Hastie, and R. Tibshirani, *An introduction to statistical learning*, vol. 112. **Springer**, 2013.
54. Gergonne, J. D., “The application of the method of least squares to the interpolation of sequences,” *Hist. Math.*, vol. 1, no. 4, pp. 439–447, 1974.
55. Stigler, S. M., “Gergonne’s 1815 paper on the design and analysis of polynomial regression experiments,” *Hist. Math.*, vol. 1, no. 4, pp. 431–439, 1974.
56. Cox, D. R. and E. J. Snell, “The choice of variables in observational studies,” *J. R. Stat. Soc. Ser. C (Applied Stat.)*, vol. 23, no. 1, pp. 51–59, 1974.
57. Myers, R. H. and R. H. Myers, *Classical and modern regression with applications*, vol. 2. **Duxbury press Belmont, CA**, 1990.
58. Thompson, M. L., “Selection of variables in multiple regression: Part I. A review and evaluation,” *Int. Stat. Rev. Int. Stat.*, pp. 1–19, 1978.
59. Thompson, M. L., “Selection of variables in multiple regression: Part II. Chosen procedures, computations and examples,” *Int. Stat. Rev. Int. Stat.*, pp. 129–146, 1978.
60. Hocking, R. R., “Criteria for selection of a subset regression: which one should be used?,” *Technometrics*, vol. 14, no. 4, pp. 967–976, 1972.
61. “ROS.org | About ROS.” <https://www.ros.org/about-ros/> (accessed Dec. 28, 2020).
62. “Overview · MAVLink Developer Guide.” <https://mavlink.io/en/about/overview.html> (accessed Dec. 28, 2020).
63. “PX4 User Guide.” <https://docs.px4.io/master/en/> (accessed Dec. 28, 2020).

64. “Gazebo : Tutorial : Beginner: Overview.” [http://gazebosim.org/tutorials?cat=guided\\_b&tut=guided\\_b1](http://gazebosim.org/tutorials?cat=guided_b&tut=guided_b1) (accessed Dec. 28, 2020).
65. “QGC - QGroundControl - Drone Control.” <http://qgroundcontrol.com/> (accessed Dec. 28, 2020).
66. “Welcome to DroneKit-Python’s documentation!” <https://dronekit.io/> (accessed Dec. 28, 2020).
67. “Home — Spyder IDE.” <https://www.spyder-ide.org/> (accessed Dec. 28, 2020).
68. Pedregosa FABIANPEDREGOSA, F. *et al.*, “Scikit-learn: Machine Learning in Python Gaël Varoquaux Bertrand Thirion Vincent Dubourg Alexandre Passos PEDREGOSA, VAROQUAUX, GRAMFORT ET AL. Matthieu Perrot,” 2011. Accessed: Dec. 28, 2020. [Online]. Available: <http://scikit-learn.sourceforge.net>.

## ÖZGEÇMİŞ

Ebubekir ÜNLÜ İlk, Orta ve Lise öğrenimini İstanbul'da tamamladı. 2011 yılında Orhan Cemal Fersoy Lisesi'nden mezun oldu aynı yıl Karabük Üniversitesi Mühendislik Fakültesi Mekatronik Mühendisliği programına başlayarak, 2016 yılında Onur Öğrencisi olarak tamamladı. Lisans sonrası bir STK Yurdunda Müdürlük vazifesini ifa ederken 2018 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim dalında Yüksek Lisans programına başladı. Tez çalışmaları sürerken, Yedek Subay olarak askerlik vazifesini tamamladı. Lisans öğrenimi sırasında birçok TÜBİTAK destekli öğrenci araştırma projelerinde, Yüksek Lisans öğrenimi sırasında ise NATO Barış ve Güvenlik Bilim Programı destekli “Yapay patlayıcı ve yasadışı malzemelerin manyetik rezonans ve MW tespiti” projesinde yer almıştır. 2020 yılında İstanbul'da bir STK'da bilişim koordinatörlüğü vazifesine başladı ve halen devam etmektedir.