



**AVİYONİKTE TEKLİ VE ÇOKLU SENSÖR HATALARININ MAKİNE
ÖĞRENMESİ İLE TESPİT EDİLMESİ VE DÜZELTİLMESİ**

Muhammed Safa AYDIN

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Muhammed Safa Aydın

27/01/2023

AVİYONİKTE TEKLİ VE ÇOKLU SENSÖR HATALARININ MAKİNE ÖĞRENMESİ İLE TESPİT EDİLMESİ VE DÜZELTİLMESİ

(Yüksek Lisans Tezi)

Muhammed Safa Aydın

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2023

ÖZET

Aviyonik sistemlerde sensörler, hava araçlarının güvenli ulaşımı ve özellikle askeri hava araçlarının görev başarımı için büyük öneme sahiptirler. Bu tez çalışması kapsamında öncelikle yaşanan havacılık kazaları ve aksaklıkları araştırılmış, aviyonik sistemlerde yer alan sensörler incelenmiş ve geçmişte farklı hatalar sonucunda kazalara ve görev başarısızlığına sebep olan hücum açısı, yakıt akış hızı ve küresel konumlama sensörleri çalışma için seçilmiştir. Bu sensörler için gerçek hata senaryoları araştırılmıştır. Hücum açısı sensörü için sabit sapma hatası durumu ve son değerde takılı kalma hata durumu, yakıt akış hızı sensörü için yakıt sızıntısını oluşturan sabit sapma hatası ve sensör iletişiminin kopmasını temsilen sıfıra düşüş hata durumu, küresel konumlama sistemi içinse gürültülü veri hata durumu oluşturulmuştur. Geliştirilen Karar Ağaçları, Destek Vektör Regresyonu, Torbalama Ağaçları ve Derin Sinir Ağları modelleriyle diğer aviyonik sistemlerden alınan sensör verileri kullanılarak seçilen sensörlerin verileri tahmin edilmiş ve hata durumları tespit edilmiştir. Çalışmada makine öğrenmesi modellerini geliştirmek ve test etmek için X-Plane uçuş simülatörü kullanılmış ve çalışmada kullanılan tüm veri seti çalışma kapsamında oluşturulmuştur. Makine öğrenmesi metotlarında en verimli modele ulaşmak için öncelikle bekletme doğrulaması kullanılmış ve her metot için en verimli model bulunmuştur. Torbalama Ağaçları metodu 40 adet öğrenme ağacıyla oluşturulduğu zaman tüm sensör verileri için en az hataya sahip model olmuştur. Geliştirilen modeller, bağımsız üç uçuş verisinde test edilmiştir. Hücum açısı verisinde ortalama kare hata miktarı 0,5936'ya kadar düşecek şekilde tahmin gerçekleştirildiği ve test uçuşlarının çoğunda hataların oluştuktan 10 saniye içinde tespit edildiği görülmüştür. Test uçuşlarında yakıt akış hızı verisi, minimum $1,03 \times 10^6$ ortalama kare hata ile yine oldukça başarılı şekilde tahmin edilmiştir ve test uçuşlarının çoğunda hata durumları yaklaşık 5 saniyede tespit edilmiştir. Küresel Konumlama sensörünün verileri için de başarılı tahminler yapıldığı görülmüştür. Çalışmada ayrıca çoklu sensör arızası durumu, yakıt akış hızı sensörünün sıfıra düşme hatasına sahip olduğu zaman hücum açısı modeline etkisi üzerinden incelenmiş ve çoklu sensör arızasında da birden fazla model kullanılarak yapılan tahminler ile hatanın düzeltilebildiği görülmüştür.

Bilim Kodu : 90541

Anahtar Kelimeler : Aviyonik, makine öğrenmesi, sensör füzyonu, hata tespiti

Sayfa Adedi : 63

Tez Danışmanı : Prof. Dr. Hasan Şakir BİLGE

SINGLE AND MULTI SENSOR FAIL DETECTION AND FIXING VIA MACHINE LEARNING METHODS IN AVIONICS

(M. Sc. Thesis)

Muhammed Safa AYDIN

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

January 2023

ABSTRACT

In avionic systems, sensors have great importance for the safe transportation and mission success of military aircraft. Within the scope of this thesis, first of all, aviation accidents and failures are inspected, the avionic system sensors are examined, and the angle of attack, fuel flow rate, and global positioning sensors which caused accidents and mission failures in the past, are selected for fault detection cases. Real fault scenarios are studied for these sensors. For the angle of attack sensor, fixed bias error situation and stuck at last value error situation; for the fuel flow rate sensor, bias error to represent fuel leakage and zero-fall error situation to represent the sensor communication breakage; and for the global positioning system, noisy data error situation is created. Using Decision Trees, Support Vector Regression, Bagging Trees, Deep Neural Networks models, and other avionic systems sensor data, the selected sensor outputs are predicted and error situations are detected. In the study, X-Plane flight simulator is used to develop and test machine learning models, and the entire dataset used in the study is created within the scope of the thesis. To find the most successful model, hold-out validation method is used. Bagging Trees with 40 learning trees is the best model that has the least error for all sensor data. The developed models are tested on three independent flight data. It has been observed that the angle of attack data can be predicted as 0,5936 in terms of mean square error and the errors are detected within 10 seconds in most of the test flights. In test flights, the fuel flow rate data is predicted successfully with minimum $1,03 \times 10^6$ mean square error, and error situations are detected in about 5 seconds in most of the test flights. It has been observed that successful estimations have been made for the data of the global positioning sensor also. In the study, the multi-sensor failure situation is also examined through its effect on the angle of attack model when the fuel flow rate sensor has a zero-fall error, and it is seen that the multi-sensor failure could be corrected by estimating using more than one model.

Science Code : 90541

Key Words : Avionics, machine learning, sensor fusion, fault detection

Page Number : 63

Supervisor : Prof. Dr. Hasan Şakir BİLGE

TEŞEKKÜR

Her zaman ve her konuda desteğini yanımda hissettiğim sevgili eşim Begüm’e, biricik kızım Defne Vera’ya ve beni yetiştirip büyüten canım aileme çok teşekkür ederim.

Tez çalışmam boyunca yardımlarını ve hoşgörüsünü benden hiçbir zaman esirgemeyen danışman hocam Prof. Dr. Hasan Şakir BİLGE’ye saygılarımı ve şükranlarımı sunuyorum. Ayrıca ders dönemi ve tez dönemi boyunca her zaman çalışanı ve öğrencisi yararına düşünen ve çalışan Aselsan’a, Dr. İbrahim Halil GİDEN’e ve çalışma arkadaşım Fatih ÇALIŞIR’a teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xi
RESİMLERİN LİSTESİ	xiii
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	5
3. AVİYONİK SİSTEMLER VE SENSÖRLER.....	7
4. UÇUŞ SİMÜLATÖRÜ VE VERİ SETİ OLUŞTURULMASI.....	13
5. MAKİNE ÖĞRENMESİ METOTLARI.....	17
5.1. Karar Ağaçları	17
5.2. Destek Vektör Regresyonu	19
5.3. Torbalama Ağaçları.....	21
5.4. Derin Sinir Ağları.....	23
6. DENEYSEL ÇALIŞMALAR	27
6.1. Hücum Açısı Verileri için Model Seçimi.....	28
6.1.1. Hücum açısı için karar ağacı modeli	28
6.1.2. Hücum açısı için destek vektör regresyonu modeli	29
6.1.3. Hücum açısı için torbalama ağaçları modeli.....	29
6.1.4. Hücum açısı için derin sinir ağları modeli	30
6.2. Yakıt Akış Hızı Verileri için Model Seçimi	30

Sayfa

6.2.1. Yakıt akış hızı için karar ağacı modeli.....	31
6.2.2. Yakıt akış hızı için destek vektör regresyonu modeli	31
6.2.3. Yakıt akış hızı için torbalama ağaçları modeli.....	32
6.2.4. Yakıt akış hızı için derin sinir ağları modeli	32
6.3. Enlem ve Boylam Değişim Hızı Verileri için Model Seçimi	32
6.3.1. Enlem ve boylam değişim hızları için karar ağacı modeli	33
6.3.2. Enlem ve boylam değişim hızları için destek vektör regresyonu modeli .	33
6.3.3. Enlem ve boylam değişim hızları için torbalama ağaçları modeli	34
6.3.4. Enlem ve boylam değişim hızları için derin sinir ağları modeli	35
6.4. Test Verisi ile En Başarılı Öğrenme Metotlarının Bulunması	35
6.4.1. Hücum açısı verisi için metotların karşılaştırılması.....	35
6.4.2. Yakıt akış hızı verisi için metotların karşılaştırılması.....	36
6.4.3. Enlem ve boylam değişim hızı verileri için metotların karşılaştırılması ..	37
6.5. Bağımsız Sensör Hatalı Uçuş Verileri ile Model Performansı	39
6.5.1. Hücum açısı hata tespiti	39
6.5.2. Yakıt akış hızı hata tespiti	44
6.5.3. Enlem-boylam değişim hızı hata tespiti.....	50
6.6. Çoklu Sensör Hatası Durumunda Model Performansı	53
7. SONUÇ VE ÖNERİLER	57
KAYNAKLAR	59
ÖZGEÇMİŞ	63

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Kullanılan veriler ve açıklamaları	16
Çizelge 6.1. Hücum açısı-farklı min. yaprak boyutu ile geliştirilen modeller.....	29
Çizelge 6.2. Hücum açısı-farklı çekirdek fonksiyonu ile geliştirilen modeller	29
Çizelge 6.3. Hücum açısı-farklı öğrenme ağaç sayısı ile geliştirilen modeller	30
Çizelge 6.4. Hücum açısı-farklı ara katman sayısı ile geliştirilen modeller	30
Çizelge 6.5. Yakıt akış hızı-farklı min. yaprak boyutu ile geliştirilen modeller	31
Çizelge 6.6. Yakıt akış hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller.....	31
Çizelge 6.7. Yakıt akış hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller	32
Çizelge 6.8. Yakıt akış hızı-farklı ara katman sayısı ile geliştirilen modeller.....	32
Çizelge 6.9. Enlem değişim hızı-farklı min. yaprak boyutu ile geliştirilen modeller.....	33
Çizelge 6.10. Boylam değişim hızı-farklı min. yaprak boyutu ile geliştirilen modeller	33
Çizelge 6.11. Enlem değişim hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller .	34
Çizelge 6.12. Boylam değişim hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller	34
Çizelge 6.13. Enlem değişim hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller .	34
Çizelge 6.14. Boylam değişim hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller	34
Çizelge 6.15. Enlem değişim hızı-farklı ara katman sayısı ile geliştirilen modeller	35
Çizelge 6.16. Boylam değişim hızı-farklı ara katman sayısı ile geliştirilen modeller....	35
Çizelge 6.17. Test verisi ile hücum açısı için metot karşılaştırılması.....	36
Çizelge 6.18. Test verisi ile yakıt akış hızı için metot karşılaştırılması	37
Çizelge 6.19. Test verisi ile enlem ve boylam değişimi için metot karşılaştırılması.....	38
Çizelge 6.20. Bağımsız uçuş test verileriyle yapılan hücum açısı tahminleri	40
Çizelge 6.21. Bağımsız uçuş test verileriyle yapılan hücum açısı tahminleri	42
Çizelge 6.22. Bağımsız uçuş test verileriyle yapılan yakıt akış hızı tahminleri	45
Çizelge 6.23. Bağımsız uçuş test verileriyle yapılan yakıt akışı tahminleri	48
Çizelge 6.24. Bağımsız uçuş test verileriyle yapılan enlem değişim hızı tahminleri	51

Çizelge	Sayfa
Çizelge 6.25. Bağımsız uçuş test verileriyle yapılan boylam değişim hızı tahminleri ...	51

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Temel aviyonik sistemler.....	7
Şekil 3.2. F-16 aviyonik mimarisi	8
Şekil 3.3. Basitleştirilmiş gaz türbinli motor çizimi	9
Şekil 3.4. Hava veri bilgisayarının çalışma sistemi	9
Şekil 3.5. Ataletsel navigasyon birimlerinin çalışma sistemi	10
Şekil 4.1. X-Plane kayıt verileri ayar ekranı.....	15
Şekil 5.1. Karar ağacı örneği.....	18
Şekil 5.2. DVR modeli örneği.....	21
Şekil 5.3. Torbalama ağaçları şeması	23
Şekil 5.4. Üç ara katmanı olan bir derin sinir ağı örneği	24
Şekil 5.5. Ara katmandaki bir nöronun veri işlemesi diyagramı	24
Şekil 6.1. Hücum açısı için en iyi modelin test verisi performansı	36
Şekil 6.2. Yakıt akış hızı için en iyi modelin test verisi performansı	37
Şekil 6.3. Enlem değişim hızı için en iyi modelin test verisinde performansı.....	38
Şekil 6.4. Boylam değişim hızı için en iyi modelin test verisinde performansı	39
Şekil 6.5. Test uçuş-1 için hücum açısı sensörü bias hatası oluşumu.....	40
Şekil 6.6. Test uçuş-1’de oluşan bias hatası ve model tahminleri	41
Şekil 6.7. Test uçuş-2’de oluşan bias hatası ve model tahminleri	41
Şekil 6.8. Test uçuş-3’te oluşan bias hatası ve model tahminleri	41
Şekil 6.9. Test uçuş-3 için hücum açısı sensörü takılı kalma hatası oluşumu	42
Şekil 6.10. Test uçuş-1’de oluşan son değer hatası ve model tahminleri	43
Şekil 6.11. Test uçuş-3’te oluşan son değer hatası ve model tahminleri	43
Şekil 6.12. Test uçuş-2’de oluşan son değer hatası ve model tahminleri	44
Şekil 6.13. Test uçuş-1 için yakıt sızıntısı hatası oluşumu	45
Şekil 6.14. Test uçuş-1’de oluşan yakıt sızıntısı hatası ve model tahminleri	46

Şekil	Sayfa
Şekil 6.16. Test uçuş-2’de oluşan yakıt sızıntısı hatası ve model tahminleri	47
Şekil 6.15. Test uçuş-3’te oluşan yakıt sızıntısı hatası ve model tahminleri	46
Şekil 6.17. Test uçuş-3 için sıfıra düşme hatası oluşumu	47
Şekil 6.18. Test uçuş-1’de oluşan sıfıra düşme hatası ve model tahminleri	48
Şekil 6.19. Test uçuş-2’de oluşan sıfıra düşme hatası ve model tahminleri	49
Şekil 6.20. Test uçuş-3’te oluşan sıfıra düşme hatası ve model tahminleri	49
Şekil 6.21. Test uçuş-3 için gürültülü veri hatası oluşumu.....	50
Şekil 6.22. Test uçuş-1’de boylam değişim hızı ve model tahminleri.....	51
Şekil 6.23. Test uçuş-2’de boylam değişim hızı ve model tahminleri.....	52
Şekil 6.24. Test uçuş-3’te boylam değişim hızı ve model tahminleri.....	53
Şekil 6.25. Test uçuş-1’de yakıt arızasının hücum açısı tahminine etkisi	54
Şekil 6.26. Test uçuş-1’de düzeltilen yakıt arızasının hücum açısı tahminine etkisi	54
Şekil 6.27. Test uçuş-2’de düzeltilen yakıt arızasının hücum açısı tahminine etkisi	55
Şekil 6.28. Test uçuş-3’te düzeltilen yakıt arızasının hücum açısı tahminine etkisi	55

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 4.1. X-Plane uçuş simülatörü kapağı	13
Resim 4.2. X-Plane F-16 modeli.....	14

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

fit	havacılıkta kullanılan uzunluk birimi, 0,3048 metredir.
g	yerçekimi ivmesi
knot	havacılıkta kullanılan hız birimi, 0,514 metre/saniye'dir.
mach	ses hızı.
pound	havacılıkta kullanılan ağırlık birimi, 0,4535924 gramdır.
radyan	açı ölçüsü birimi, 57,2957795 derecedir.

Kısaltmalar

Açıklamalar

ADC	Hava Veri Bilgisayarı (Air Data Computer)
AIFF	Gelişmiş Dost-Düşman Sorgulama (Advanced Interrogation Friend Foe)
BADA	Uçak Veri Tabanı (Base of Aircraft Data)
bias	sapma, meyil.
CADC	Merkezi Hava Veri Bilgisayarı (Central Air Data Computer)
CART	Sınıflandırma ve Regresyon Ağacı (Classification and Regression Tree)
CPU	İşlemci (Central Processing Unit)
CSFDR	Kokpit Ses ve Uçuş Veri Kaydedici (Cockpit Sound Flight Data Recorder)
DSA	Derin Sinir Ağları
DTE	Veri Transfer Ekipmanı (Data Transfer Equipment)
DVM	Destek Vektör Makineleri

Kısaltmalar**Açıklamalar****DVR**

Destek Vektör Regresyonu

ENGINE

Motor

EUPDGGelişmiş Yükseltilmiş Programlanabilir Ekran
Oluşturucu (Enhanced Upgraded Programmable
Display Generator)**Eş.**

Eşitlik

EWMSElektronik Harp Yönetim Sistemi (Electronic Warfare
Management System)**FAA**Federal Havacılık İdaresi (Federal Aviation
Administration)**FCR**

Atış Kontrol Radarı (Fire Control Radar)

FMS

Uçuş Yönetim Sistemi (Flight Management System)

GB

Gigabyte

GHz

Gigahertz

GPSKüresel Konumlama Sistemi (Global Positioning
System)**GSR**

Gauss Süreç Regresyon

Hab. Sis.

Haberleşme Sistemleri

HMD

Kaska Monteli Gösterge (Helmet Mounted Display)

HUMSSağlık ve Kullanım İzleme Sistemleri (Health and
Usage Monitoring Systems)**IDM**

Geliştirilmiş Veri Modemi (Improved Data Modem)

IMU

Ataletsel Ölçüm Birimi (Inertial Measurement Unit)

INU

Ataletsel Seyrüsefer Birimi (Inertial Navigation Unit)

INSAtaletsel Seyrüsefer Sistemi (Inertial Navigation
System)**KA**

Karar Ağaçları

KKS

Küresel Konumlama Sistemi

K-EYK

K-En Yakın Komşu

LHP

Sol Nokta (Left Hardpoint)

MFDSÇok Fonksiyonlu Ekran Sistemi (Multifunctional
Display System)

Kısaltmalar**Açıklamalar****min.**

Minimum

MMC

Modüler Görev Bilgisayarı (Modular Mission Computer)

ms

milisaniye

NASA

Amerikan Ulusal Havacılık ve Uzay Dairesi (National Aeronautics and Space Administration)

Nav.Sis.

Navigasyon Sistemleri

OKH

Ortalama Kare Hata

RALT

Radar Altimetre

RHP

Sağ Nokta (Right Hardpoint)

RPM

Dakika başına atılan devir (Round Per Minute)

s

saniye

TA

Torbalama Ağaçları

UFC/MLDEEU

Yukarı-Ön Kontrol/Ortaömür Elektronik Veri Giriş Birimi (Up-Front Control/Midlife Data Electronic Entry Unit)

1. GİRİŞ

Havacılık ve uçuş fikri, yüzyıllardır insanoğlunun zihnini kurcalasa da 1903 yılında Wright kardeşlerin gerçekleştirdiği motorlu ilk uçuş, bu konuda bir devrim olmuştur. O tarihten bu yana hava araçlarının sivil hayatta ve askeri amaçlar için kullanımının artması, havacılığı, teknolojik gelişme alanlarından biri haline getirmiştir. Sivil kullanım için emniyet, askeri kullanım için emniyetin yanı sıra kabiliyet, araçların yaygınlaşmasının önünü açan önemli etkenlerdir. Havacılıkta da yüksek teknolojinin artan kullanımı, hava araçlarını daha güvenilir ve daha kabiliyetli araçlar olmalarını sağlamıştır.

İngilizceden dilimize geçmiş ve “havacılık elektroniği” ifadesinin kısaltması olarak kullanılan aviyonik kelimesi hava araçlarında yer alan tüm elektronik sistemlere verilen genel bir isimlendirmedir. Aviyonik sistemler, bu araçların görevlerini gerçekleştirmesini sağlayan en önemli bileşenlerdendirler. Bu sistemler içerdikleri sensörler ve sensörlerden gelen verileri anlamlandıran donanım ve yazılımlarla hava araçlarına emniyet ve kabiliyet katarlar. Araçların fonksiyonlarını sağlayabilmeleri ve görevlerini yerine getirebilmeleri, sensörlerin ve dolayısıyla aviyonik sistemlerin sağladığı verilerle doğrudan ilişkilidir.

Emniyetli uçuşun sağlanabilmesi için aviyonik mimari tasarımları, sensörler ve aviyonik sistemler için yedeklilik içerebilir. Yedeklilik çözümü sensörlerin birinde gerçekleşen arızanın emniyet ve işlevselliğe olan olumsuz etkisinin önüne geçer ancak buzlanma, toz fırtınası ile tıkanma gibi çevresel etkenler sebebiyle oluşan arıza durumlarında aynı koşullar tüm sensörlerde etki göstereceğinden dolayı yedeklilik katkı sağlamaz. Ayrıca cihaz sayısının artışı, uçuş emniyetine olumlu etki etse dahi hacim, ağırlık, sürtünme gibi sebeplerden dolayı yetenek azalışına ve hatta kaybına neden olduğu için özellikle askeri uygulamalarda yedeklilik göz ardı edilebilmektedir. Her ne kadar sivil aviyonik mimari tasarımlarında sensör yedekliliği göz önünde bulundurularak tasarımlar yapılsa da bu cihazların arızaları sebebiyle birçok kaza ve işlev kaybı örneği mevcuttur. 2018 yılında Lion Air'ın 610 numaralı uçuşunda Boeing 737-8(MAX) tipi uçağın Hücum Açısı (Angle-of-Attack) sensöründe meydana gelen sabit 22 derecelik bir hata, uçak otomatik pilot sisteminin yanlış kararlar vermesine neden olmuş ve uçak kırıma uğramıştır [1]. 2019 yılında aynı tip uçak bu sefer sağ ve sol Hücum Açısı sensörlerinde meydana gelen 59 derecelik bir sapma sebebiyle kaza geçirmiştir [2]. 2014 yılında Airbus A321 tipi uçakta hücum açısı sensörünün

bloke olmasından ötürü otomatik pilotun yanlış yönlendirildiği, uçağın kontrolü kaybedildiği ve güçlkle kazanıldığı raporlanmıştır [3]. A320 tipi uçağın 2008 yılında yaptığı kaza ise hücum açısı sensörünün son deęerde takılı kalması sebebiyle gerçekleşmiştir [4]. 2001 yılında gerçekleşen Air Transat uçuş 236 kazasında ise 2 numaralı motorda oluşan sızıntı yakıt bitişine neden olmuştur, uçağın yakıt akış hızında gerçekleşen normal dışı akış tespit edilmemiş olması kazaya zemin hazırlamıştır [6].

Öte yandan sensörlerden gelen verilerin hatalı olmasının tek nedeni sensör arızaları değildir. Uçuş öncesi gerekli sensör kalibrasyonunun yapılmaması, hatalı cihaz takılması, cihaz üzerinde unutulmuş ekipmanlar gibi insan hatalarından dolayı da sensörlerin doğru veriler üretemediği olaylar yaşanmıştır. Örneğin, 2005 yılında Tuninter'in 1153 numaralı uçuşundan önce analog yakıt sensörü kokpit göstergesinde yanlış ekipman yerleştirilmesi sebebiyle sensör verisi hatalı şekilde pilotlara gösterilmiş ve uçak yakıt bitmesi sebebiyle düşmüştür [6]. 1996 yılında gerçekleşen kazada ise uçuştan önce uçağı yıkayan görevli irtifa ölçümü yapan pitot tüplerini bantlamış ancak sonrasında çıkarmayı unuttuğu için hatalı sensör verisi nedeniyle uçak düşmüştür [7].

Sensör verilerinin hatalı olmasının bir dięer nedeni ise özellikle askeri hava araçlarının maruz kaldığı elektromanyetik ve siber saldırılardır. Aldatma ve karıştırma elektromanyetik taarruzlar için ve sızma ise siber saldırılar için örnek teşkil etmektedir. Bu tür saldırılar sebebiyle oluşan sensör hataları için de yedeklilik üzerine kurulu mimari çözüm olamamaktadır. Amerikan Ulusal Havacılık ve Uzay Dairesi (NASA), 2019 yılında Küresel Konumlama Sistemi (GPS) karıştırmasının sivil ulaşımı sağlayan bir uçağın neredeyse yere çarpmasına sebep olduğunu duyurmuştur [8]. 2011 yılında İran güçleri, Lockheed Martin RQ-170 Sentinel tipi insansız hava aracının GPS aldatmacası kullanılarak ele geçirdiğini duyurmuş, Amerikalılar bunu yalanlayınca ise olayın videosunu paylaşmışlardır [9].

Sensör hataları sebebiyle oluşan emniyetsiz durumlar ve işlev kayıpları için sivil havacılıkta oldukça fazla örnek bulunurken, askeri havacılık için bu hatalar gizli tutulmaktadır. Askeri hava araçlarında sivilden farklı olarak emniyetin yanı sıra görev başarısı için de aviyonik sistem ve sensörlerin doğru veri vermesi gerekmektedir. Örneğin, sınır ihlali yapan bir hava aracına angajman uygulama yeteneği yakıt miktarı ile doğrudan ilişkilidir, yakıt miktarının doğru hesaplanması için de yakıt akış sensörü verisi sağlıklı olmalıdır. Bir başka örnekte ise GPS aldatmacasına uğrayan bir askeri hava aracı, kendi konumunu referans vererek

bildirdiği hedef hava aracını hatalı raporladığı için görevini başarılı şekilde icra edememiş olur. Askeri havacılıkta, yetenek kaybı ve operasyonel kısıtların yaşanmaması için sensör verilerinin hatalı şekilde işlenmemesi gerekmektedir.

Makine öğrenmesi modelleri, geçmiş verilerin deneyimiyle öğrenebilen, yinelemeli şekilde performansını geliştirebilen ve sonrasında ilk kez karşılaştığı bir durumda akıllı kararlar verebilen algoritmalardır. Modellerin başarılı olması için en önemli ihtiyaç, hedef çıktı ile ilişkili girdilerin yer aldığı kapsamlı bir veri setidir. Hava araçları, her biri farklı amaca hizmet ederken aynı kompleks sistemin içinde yer aldığı için benzer şartlarda çalışan onlarca hatta yüzlerce sensör içerir. Sensörlerin çoğu birbirleriyle haberleşmeden çalıştıkları için diğer sensör verilerinden çıkarım yapamazlar. Öte yandan modern kompleks hava araçlarında çoğu aviyonik sistemlerle iletişim halinde olan ekipman ya da ekipmanlar mevcuttur.

Bu tez çalışmasında, aviyonik sensör verileri toplanarak bu sensörlerin arızalı ya da anormal veri ürettiği durumların tespiti ve düzeltilmesi üzerine çalışılmıştır. Tespit etmek ve düzeltmek için hatalı sensörün iletişimde bulunmadığı diğer sensörlerin verileri kullanılarak geliştirilen makine öğrenmesi metotları kullanılmıştır. Çalışmada, regresyon analizi yapabilen öğrenme modellerinden Destek Vektör Makineleri (DVM), Karar Ağaçları (KA), Torbalama Ağaçları (TA) ve Derin Sinir Ağları (DSA) kullanılmış, hava aracı olarak jet motorlu askeri uçak olan F-16 uçağı seçilmiştir. Tez çalışmasının önemli bir aşaması olarak eğitim veri setleri X-Plane uçuş simülatörü kullanılarak elde edilmiş ve test uçuşları da bu platform üzerinde gerçekleştirilmiştir. Test uçuşlarında aviyonik sensörlerde gerçekçi hata durumları oluşturulmuş, tekli ve çoklu sensör hata durumlarında geliştirilen öğrenme modellerinin performansları incelenmiştir.

Bu tez çalışması kapsamında literatürde yer alan hava araçlarında ve aviyonik sensörlerde öğrenme modelleri kullanılarak yapılan arıza tespit uygulamaları Bölüm 2’de verilmiştir. Bölüm 3’te Aviyonik Sistemler ve Sensörler ile ilgili bilgilendirmeler yapılmıştır, ayrıca çalışmada kullanılacak sensörlerin seçimlerinden ve hata durumlarından bahsedilmiştir. Bölüm 4, uçuş simülatörü hakkında bilgilendirmeleri ve veri seti oluşturma aşamasını içermektedir. Çalışmada kullanılan makine öğrenmesi metotları hakkında açıklamalar ve öğrenme mantıkları ise Bölüm 5’te verilmiştir. Bölüm 6, farklı hata senaryolarındaki model performanslarını ve karşılaştırmalarını, deneysel çalışmaların sonuçlarını ve

değerlendirmelerini içermektedir. Bölüm 7’de tez çalışmasının özeti niteliğinde genel çıkarımlar ve öneriler yer almıştır.

2. LİTERATÜR TARAMASI

Aviyonik sistem arızasının tespiti için bu zamana kadar birçok farklı çalışmalar yapılmış ve uygulamalar oluşturulmuştur. İlk aşamada, hava aracı yerde iken gerçekleşen bakım uygulamaları yaygınlaşmıştır. 1990'ların başında geliştirilmeye başlayan HUMS (Health and Usage Monitoring Systems) adı verilen cihazlar, hava aracının farklı noktalarında titreşim, sıcaklık vb. ölçümleri gerçekleştirerek uçuş süresince kayıt yaparlar, daha sonra bakım ekibinin bu kayıtları incelemesiyle olası arızanın tespiti gerçekleştirilir [10]. Ancak yerde yapılan uygulamalar, hava aracı görevdeyken ortaya çıkan hataları tespit edemezler. Teknolojinin ve bilgisayar biliminin gelişmesiyle havada hata tespit çalışmaları yapılmış ve uygulamaları kullanılmaya başlanmıştır.

Makine öğrenmesi ile sensör verilerinin tahmini konusunda ilk çalışmaları McCool ve diğerleri yapmıştır. Geliştirdikleri sinir ağları modeliyle iki farklı helikopter tipi için düşük hızlarda, hava hızı ve rüzgar yönü tahmini modeli geliştirmişler ve hava hızını 6 knot (deniz mili/saat) doğrulukla, rüzgar yönünü ise 4 ana yön tahmini yaparak %95'e varan doğrulukla tahmin edebilmişlerdir [11]. Bir diğer çalışmada ise Srivastava, uçuş simülasyonu ile elde edilen ve gerçek uçak üzerinden alınan farklı cihazlara ait veriler kullanarak yakıt tüketiminin Gauss Süreç Regresyon (GSR), karar ağaçları, sinir ağları ve genelleştirilmiş lineer modelini içeren kolektif torbalama (ensemble bootstrap-aggregating) regresyon öğrenmesi ile tahmin edilebileceğini ve bu sayede yakıt tüketiminde anormallik olan uçakların tespit edilebileceğini göstermiştir [12]. 2017 yılında Chati ve Balakrishnan tarafından yapılan çalışmada ise GSR kullanılarak yapılan yakıt akışı tahminin hali hazırda kullanılan BADA (Base of Aircraft Data) modelinden daha iyi sonuç verdiği görülmüştür [13].

Oza ve Das, Destek Vektör Regresyonu (DVR) kullanarak geliştirdikleri model ile 495 uçuşun 14'ünde yakıt tüketiminin anormal olduğunu tespit etmişler ve daha sonra bu modelin tespit ettiği bu uçuşların bir kısmında arızadan dolayı uçuşun iptal edildiğine ulaşmışlardır [14]. Qiancheng ve diğerleri, küçük boyutta veri seti ile aviyonik arızasını DVR ile diğer makine öğrenmesi metotlarından daha başarılı şekilde bulmuşlardır [15]. 2017'de yapılan bir araştırmada ise bir insansız hava aracı simülasyonundaki jiroskop ve ivmeölçer verileri kullanılarak DVR ile eyleyici arızası tespiti gerçekleştirilmiştir [16]. Yan


ve Zhou, Rastgele Orman öğrenme modelini farklı sensörlerden gelen verilerle geliştirmişler ve motor arızasını uçakta kullanılan arıza tespit sisteminden daha başarılı şekilde tahmin etmişlerdir [17].

Swischuk ve Allaire'in 2018'de yaptığı çalışmada, hava hızı tahmini için kullanılan pitot statik tüplerinin tıkanması arızası K-En Yakın Komşu (K-EYK) modeliyle 20 saniye içinde tespit edilmiştir ve düzeltilmiştir, bu çalışmada hatalar manuel olarak eklenmiştir [18]. 2021 yılında yapılan bir çalışmada ise Tekrarlayıcı Sinir Ağları kullanılarak F-16 uçağı için hücum açısı, hatalı hız ve hatalı yunuslama açısı içeren veri setinde dahi başarılı şekilde tahmin edilmiştir [19]. Shafiee ve diğerlerinin yaptığı çalışmada ise GPS aldatmacasının tespiti, GPS alıcısına gelen sinyal verileri kullanılarak geliştirilen Naïve Bayes, K-EYK ve sinir ağları modelleri ile yapılmıştır [20]. 2021 yılında yapılan bir çalışmada ise Kılıç ve Ünal, gerçek uçuş verileri kullanarak hava veri bilgisayarında gerçekleştirebilecek hataları sinirsel bulanık çıkarım sistemi ve yapay sinir ağları kullanarak tespit etmişler ve düzeltmişlerdir [21]. 2020 yılında ise insansız hava araçlarında arızalar destek vektör makineleri modeliyle %95 doğrulukla tespit edilmiştir [22].

Verilen çalışmalar, havacılıkta ve aviyonik sistemlerde arıza ve hata tespitleri için farklı makine öğrenmesi modellerinin kullanımını içermektedir. Bu tez çalışmasında ise uçuş simülatörü kullanılarak veri seti elde edilmiş, bu veri seti ile modeller oluşturulmuştur ve modellerin performansları karşılaştırılmıştır. Aviyonik sensörlerin gerçek hata durumları test veri setine eklenerek makine öğrenmesi ile hata tespit uygulamasının tekli ve çoklu sensör arızalarındaki başarımları incelenmiştir.

3. AVİYONİK SİSTEMLER VE SENSÖRLER


Aviyonik sistemler hava aracının güvenli şekilde görevini yerine getirebilmesi için tasarlanır ve araca yerleştirilir. Her sistemin işlevi farklıdır ve fonksiyonları şu şekilde sıralanabilir: seyrüsefer, haberleşme, uçuş kontrol, gösterge, motor ve yakıt yönetimi, hedefleme ve görüntüleme.



Şekil 3.1. Temel aviyonik sistemler [23]

Şekil 3.1’de temel aviyonik sistem mimarisinin bir kısmı örnek olarak verilmiştir. Hava araçları için cihaz farklılıkları olsa dahi yerine getirdikleri fonksiyonlar benzerdirler. Gösterge, veri giriş, haberleşme, hedefleme ve görüntüleme gibi fonksiyonları yerine getiren aviyonik sistemler, araç için önemli olsalar da bu tez çalışmasının konusunu oluşturan sensörleri içermezler. Motor ve yakıt sistemindeki sensörler ve seyrüsefer sistemleri içerisinde yer alan ataletsel navigasyon cihazları, hava veri cihazları, radar altimetreler, küresel konumlama cihazlarında yer alan sensörler hava aracının başarılı şekilde ulaşımında en önemli rolü üstlenirler. Bu sensörler askeri hava araçlarında ek olarak aracın görevlerini gerçekleştirebilmeleri için gerekli verileri üretirler ve görev sistemine aktarılırlar. Bu sistemlerin işlevleri aynı olmalarına rağmen hava aracına özel cihazlarda farklılıklar vardır. O yüzden bir hava aracına özel yapılan tasarımların o araçtaki sistemlere uygun şekilde oluşturulması gerekmektedir.


Bu tez çalışması için F-16 uçağı seçilmiştir. Bu hava aracı askeri olduğu için sensör yedekliliğın kısıtlı olması, operasyonel kullanımda elektronik taarruzlarla sensör kaybına uğramasının daha olası olması ve popüler bir uçak olduğu için veri seti oluşturma olanağının bulunması nedenlerinden ötürü seçilmiştir.



Şekil 3.2. F-16 aviyonik mimarisi [24]


Çalışma için seçilen F-16 uçağının aviyonik mimarisi Şekil 3.2’de verilmiştir. Şekilde verildiği üzere Modüler Görev Bilgisayarı (MMC) tüm aviyonik sistemlerle veri yolları üzerinden iletişim kurmakta ve tüm alt sistemlerin bilgisini toplamaktadır.

F-16 uçağı tek gaz türbinli turbofan motora sahiptir. Şekil 3.3’te bir gaz türbinli motorun basitleştirilmiş çizimi verilmiştir. Motor ve yakıt sistemindeki sensörler, Şekil 3.2’de ENGINE (Motor) olarak belirtilen sistem aracılığıyla aktarılır. Çalışmada veri seti oluşturulurken motorun dakikada attığı turu (RPM) ifade eden N1 ve N2 parametreleri kullanılmıştır. N1 motordaki düşük basınç makarasının hızını, N2 yüksek basınç makarasının hızını yüzdesel olarak ifade etmektedir. Motor-yakıt sisteminden alınan bir diğer veri ise yakıt akış hızı verisidir. Motora giden yakıt pound/saat cinsinden ölçülmüştür. Bu sistemden alınan üç veri de motor yakıt sisteminde üretilir ve ilgili sistemlere iletilir.



Şekil 3.3. Basitleştirilmiş gaz türbinli motor çizimi [25]


Bu tez çalışmasında sensörlerinin verileri kullanılan bir diğer ekipman ise seyrüsefer verilerinin bir kısmını sağlayan hava veri bilgisayarı cihazıdır. Şekil 3.4'te bir hava veri bilgisayarı cihazının çalışma sistemi verilmiştir.



Şekil 3.4. Hava veri bilgisayarı çalışması [26]

Hava veri bilgisayarı, uçakta bulunan pitot ve statik basınç sensörleri, hava termometresi, hücum açısı algılayıcısından aldığı verileri kullanarak ürettiği kalibre edilmiş, işari ve gerçek hava hızları, hava basıncı, irtifa, mach sayısı, dış hava sıcaklığı, hücum açısı, dikey yükseliş hızı verilerini görev sistemlerine ve kokpit göstere sistemlerine iletirler. Şekil 3.4'te verilen sensörlerden statik basınç sensörü ile dikey yükseliş hızı ve irtifa ölçülürken, termometre, statik basınç ve pitot basınç sensörleri birlikte kullanılarak hava hızları, mach sayısı ve hava basıncı ölçülür. Hücum açısı sensörünün üretilen verinin kullanıldığı çıktı ise hücum açısı verisidir [27]. Tez çalışmasında hava veri bilgisayarı üretilen kalibre edilmiş, işari ve gerçek hava hızları, irtifa, mach sayısı, hücum açısı, dikey yükseliş hızı verileri kullanılmıştır.

F-16'da irtifa veren bir diğer ekipman ise Radar Altimetrelerdir. Radar altimetre, hava veri bilgisayarının aksine deniz seviyesine yüksekliğini değil yerden yüksekliği uçağın üzerinden bir radar sinyali yollayarak vermektedir. Bu tez çalışmasında kullanılan verilerden biri de yerden yükseklik verisidir.



Şekil 3.5. Ataletsel navigasyon birimlerinin çalışma sistemi [28]

Aviyonik mimaride INU olarak belirtilen ataletsel navigasyon birimleri tüm uçaklarda bulunan seyrüsefer ekipmanıdır. Ataletsel navigasyon birimlerinde yer alan jiroskoplar ve ivmeölçerler kullanılarak, uçağın yere göre hızları, ivmeleri, oryantasyonu elde edilir. İlk pozisyon verilirse uçağın konumu da kestirilebilir. Şekil 3.5'te ataletsel navigasyon birimlerinin genel çalışma mekanizması verilmiştir. Çoğunlukla küresel konumlama sistemleri ile birlikte kullanılan ataletsel navigasyon sistemleri birlikte kullanımda da ham verisini paylaşmaktadır. F-16 mimarisinde de küresel konumlama sistemi ile ayrı şekilde verilmiştir. Ataletsel navigasyon biriminden gelen yer hızı, baş bilgisi, ivmeler, rüzgar bilgileri, yunuslama, yatış, baş açıları ve açıların değişim hızları bu çalışmada veri olarak kullanılmıştır.

Küresel konumlama sisteminden gelen konum verisi bu çalışmada kullanılmıştır. Küresel konumlama sistemleri başka bir cihazdan gelen veriye ihtiyaç olmadan uçak enlem ve boylamı verebilmektedir. Bu çalışmada enlem ve boylam değişimi veri olarak enlem-boylam ve zaman aralığı verilerinden elde edilmiş, kullanılmıştır.

Tez çalışmasında, üç sensör için hata olması durumları incelenmiştir. Seçilen üç sensör yakıt akış hızı, hücum açısı ve konumu ölçen algılayıcılardır. Bu sensörler seçilirken kendilerine özel çıktılarının olmasına dikkat edilmiştir. Bu şekilde bir sensörün arızasıyla başka sensör

verilerinin ya da hesaplamalarının bozulma durumu olmaması hedeflenmiş ve gerçekleşmesi ihtimali olan değişimler göz ardı edilmiştir. Bu sensörlerin verilerinde gerçekçi hata durumları bozulma gerçekleşmemiş uçuşlara eklenmiştir ve makine öğrenmesi modelleriyle tespit edilmiştir.

Seçilen birinci algılayıcı yakıt akış hızını ölçen sensördür. Bu sensör verisi motora giren yakıtı ölçer ve bu cihaz için iki hata durumu modellenmiştir. Birinci hata durumu 2001 yılında meydana gelen kazada yaşanan motorda yakıt sızıntısı görülme durumudur. Bu durum bir sensör arızası olmasa da yakıt akış hızındaki anormallik tespit edilebilirdi [6]. Bu durumu oluşturmak için yakıt akışı hızına sapma (bias) eklenmiştir ve hata durumu tespit edilmeye çalışılmıştır. İkinci hata durumu karmaşık sistemlerde sıkça yaşanabilen sensörle iletişimin kopması durumudur. Bu durumu modellemek için sıfıra düşme hatası veriye eklenmiştir ve tespit edilmeye çalışılmıştır.

Seçilen ikinci sensör hücum açısı algılayıcısıdır. Uçak üzerinde hücum açısını ölçen ayrı bir birim üzerinden hava veri cihazında üretilen sensör verisi için de iki farklı arıza durumu modellenmiştir. Birinci arıza durumu Boeing 737-8(MAX) tipi uçakların kazasına neden olan sabit hatalı veri üretilmesi (bias) durumudur. Lion Air kazasında yaşanan 22 derecelik sabit hata sensör verisine eklenmiştir. İkinci hata durumu ise 2008 yılındaki kazaya sebebiyet veren son değerde takılı kalma hatasıdır. Bu hata durumu da uçuşun bir noktasındaki verinin uçuş sonuna kadar üretilmesi şeklinde diğer hatalar gibi elle eklenerek oluşturulmuştur.

Üçüncü sensör hatası durumu ise küresel konumlama sisteminde üretilen konum verisi için oluşturulmuştur. Askeri hava aracı GPS'leri sıklıkla karıştırmaya maruz kalmaktadırlar. Konum verisi için gürültülü veri durumu enlem değişimi ve boylam değişimi verileri bozularak oluşturulmuş ve tahminler gerçekleştirilmiştir.

4. UÇUŞ SİMÜLATÖRÜ VE VERİ SETİ OLUŞTURULMASI

Tez çalışmasının bir kısmı veri seti üretme aşamasından oluşmaktadır. Makine öğrenmesi modellerinin ortaya çıkarılması, eğitilmesi ve sonunda da test edilip değerlendirilmeleri için veri seti büyük öneme sahiptir. Ancak askeri hava araçları için gerçek uçuş verileri istihbarat anlamında bilgi içerdiği için bu verilere ulaşım pek mümkün değildir. Bu sebeple bu çalışmada simülasyon ortamı ve uçuş verileri kullanılmıştır. Simülasyon ortamları gerçek dünyayı kontrol edilebilir şekilde temsil ederler ve sistemlerin farklı ortamlardaki işlevselliği hakkında testler yapılması ve doğrulanması için havacılıkta kullanılırlar [29]. Literatürde simülasyon uçak verileri ile geliştirilmiş makine öğrenmesi çalışmaları mevcuttur [16, 19, 30]. Bu çalışmada da veri seti oluşturulurken Laminar Search tarafından geliştirilen X-Plane simülatörünün 10.42 versiyonu kullanılmıştır. X-Plane'nin çalıştığı bilgisayar ise 80 GB Ram'e sahip Intel(R) Core(TM) i7-4790K CPU @ 4.00GHz bilgisayardır.



Resim 4.1. X-Plane uçuş simülâtörü kapağı [31]

Geliştiricileri tarafından oyun olarak değil bir mühendislik aracı olarak nitelendirilen X-Plane uçuş simülâtörü büyük savunma sanayii şirketleri, hava kuvvetleri, hava aracı üreticileri tarafından yoğun şekilde kullanılmaktadır [29]. Farklı sabit kanatlı ve döner kanatlı hava araçlarını manipüle edilebilir çevre şartlarında kontrol imkânı sağlayan simülâtör, Federal Havacılık İdaresi (FAA) tarafından onaylanan bir uçuş simülâtörüdür [32]. Ayrıca 2011 yılında yapılan çalışmada bir Cessna 172 tipi uçak gerçek dünyada


u urulmu  ve X-Plane’de de Cessna 172 tipi u ak se ilerek sim lat r ortamında u urulmu tur. Her iki u u , havada tutunamama, sabit d n   ve u u  yolu kararlılı ı y n nden kar ıla tırılmı  ve bu u u lar yazar tarafından ‘‘dikkat  ekici  ekilde benzer’’ diye nitelendirilmi tir [33]. 2016’da yapılan bir  alı mada X-Plane u u  sim lat r  ile ger ek u u  verisine benzer hatta daha kapsamlı bir veri seti olu turulabilece ini g sterilmi tir [34].

Bu tez  alı masında da F-16 u a ının modeli X-Plane u u  sim lat r nde se ilerek farklı konumlarda ve  evre  artlarında u u lar ger ekle tirilmi tir. Sim lat r n ‘‘Get me lost’’ (beni kaybet)  zelli i kullanılarak rasgele konumlarda ve havada olacak  ekilde u u lara ba lanmı tır. U u lar tırmanı , d z u u  ve al alı  safhalarını i erecek  ekilde ger ekle tirilmi tir. Bunun sebebi ise Boeing’in 2020 yılında yayınladı ı ve son on yıllık u ak kaza istatistiklerine g re u akta meydana gelen  l mc l olayların %53’  tırmanı , d z u u  ve al alı  safhalarında ger ekle mi tir [35]. U u lar bir kokpit ortamında otomatik olmayacak  ekilde Thrustmaster markasının  retti i ve F-16 u u  kontrol kumandalarının kopyası Cougar modeli kullanılarak ger ekle tirilmi tir.



Resim 4.2. X-Plane F-16 modeli

X-Plane sim lat r  u u  verilerinin bir dosyaya yazılmasını desteklemektedir. Sim lat r ara y z nden yazılması istenen veriler ve kayıt frekansı se ilebilmektedir. Bu tez  alı ması i in periyot olarak 200 ms ayarlanmı  ve kayıt istenen veriler  ekil 4.3’teki gibi se ilmi tir.  ekilde g r len her bir veri grubu i in d rt adet se ilebilir alan g r lmektedir, bu alanlardan ikincisi dosyaya kayıt i in se im yapılıp yapılmadı ını g stermektedir.



Şekil 4.1. X-Plane kayıt verileri ayar ekranı

Kaydedilen verilerin tamamı makine öğrenmesi modelleri için kullanılmamış yalnızca Çizelge 4.1’de detaylı bilgisi yer alan veriler model geliştirme için kullanılmıştır. Model geliştirme için kullanılacak verilerin seçimi yapılırken, verilerin F-16 uçağı mimarisinde ulaşılabilir ve paylaşılabılır olmasına dikkat edilmiştir. X-Plane tarafından çıktı olarak verilen enlem ve boylam bilgisi doğrudan kullanılmamıştır, birim zamanda enlem değişimi ve birim zamanda boylam değişimi hesaplanarak veriye eklenmiştir.

Çizelge 4.1. Kullanılan veriler ve açıklamaları


Verinin X-Plane Adı	Verinin Açıklaması
Vind, kias	Uçak belirlenmiş hava hızı, birimi knot
Vind, keas	Uçak kalibre edilmiş hava hızı, birimi knot
Vtrue, ktas	Uçak gerçek hava hızı, birimi knot
Vtrue, ktgs	Uçak yer hızı, birimi knot
Mach, ratio	Uçak mach numarası, 1 mach'a göre oran
VVI, fpm	Uçak dikey hızı, birimi fit/dakika
Gload, norm	Uçak gövde eksenine göre g-yükü
Gload, axial	Uçaktaki eksenel g yükü
Gload, side	Uçaktaki yanal g yükü
wind, speed	Rüzgar hızı, birimi knot
wind, dir	Rüzgar yönü
dens, ratio	Hava yoğunluk oranı
Q, rad/s	Uçak yunuslama değişim hızı, birimi radyan/s
P, rad/s	Uçak yatış değişim hızı, birimi radyan/s
R, rad/s	Uçak sapma değişim hızı, birimi radyan/s
pitch, deg	Uçak yunuslama açısı, birimi derece
roll, deg	Uçak yatış açısı, birimi derece
hding, true	Uçak baş açısı, birimi derece
alpha, deg	Uçak hücum açısı
beta, deg	Uçağın yana kayma açısı, birimi derece
alt, ftmsl	Uçağın deniz seviyesine göre irtifası, birimi fit
alt, ftagl	Uçağın yerden yüksekliği, birimi fit
N1 1, pcnt	Uçak motorunun N1 yüzdesi
N2 1, pcnt	Uçak motorunun N2 yüzdesi
FF 1, lb/h	Uçak motoruna giren yakıt akışı, birimi pound/saat
Lat_diff, dps	Uçağın enlem değişim hızı (üretilmiştir), birimi derece/saniye
Lon_diff, dps	Uçağın boylam değişim hızı (üretilmiştir), birimi derece/saniye

5. MAKİNE ÖĞRENMESİ METOTLARI

Makine öğrenmesi, edinilmiş verileri kullanarak insanların öğrenme şekillerini taklit eden algoritmalar geliştiren bilgisayar bilimine verilen addır. Bu bilimde temel amaç, toplanan verileri kullanarak kestirim ya da çıkarımlar yapabilen modeller geliştirmektir. Bu modellerin yaptığı kestirim ve çıkarımlar kategorize edilmiş çıktılar üretiyorsa sınıflandırma modelleri olarak nitelendirilir. Bağımsız değişken ve özelliklerin kullanılarak geliştirilen algoritmalar ile sürekli çıktılar üreten makine öğrenmesi modelleri, regresyon modelleri olarak isimlendirilir. Bu çalışmada hedefler kategorize edilmemiş sürekli değişen çıktılar olduğu için regresyon modelleri kullanılmıştır. Makine öğrenmesi modelleri denetimli öğrenim, denetimsiz öğrenim veya pekiştirmeli öğrenim gibi farklı öğretim metotlarıyla geliştirilebilmektedir. Bu çalışmada üretilen veri seti doğru etiketlere sahip bir set olduğu için çalışmada denetimli öğrenim teknikleri kullanılmıştır. Bu çalışmada denetimli öğrenim metotlarından regresyon analizi yapabilen şu modeller kullanılmıştır: Karar Ağaçları, Destek Vektör Makineleri, Torbalama Ağaçları ve Derin Sinir Ağları.

5.1. Karar Ağaçları

Karar Ağaçları, hem sınıflandırma hem de regresyon için kullanılan denetimli bir öğrenme yöntemidir. Karar ağacı, bir akış şeması oluşturarak karara ulaştığı yolu açık bir şekilde gösterir. Anlaması ve yorumlaması basittir ve çok fazla veri hazırlığı gerektirmez, bu da normalizasyon veya kukla (dummy) değişkenlere gerek olmadığı anlamına gelmektedir. “Geliştirilen karar ağacı, tek düğümden başlar. Bu noktadan başlayarak her düğüm en az iki parçaya ayrılır, bölünerek dallanır. Her dal nihai yaprağa ulaşmaya kadar yeni dallar oluşturularak model geliştirme devam eder. Sonunda çıkan model, ağaca benzediğinden karar ağaçları ismini almıştır” [36]. Klasik bir karar ağacı modeli örneği Şekil 5.1’de verilmiştir.



Şekil 5.1. Karar ağacı örneği [37]

Ağaç oluşturulurken farklı algoritmalar kullanılırken bu çalışmada kullanılan teknik regresyon analizlerinde de kullanılan CART (Classification and Regression Tree) algoritmasıdır. Bu teknikte ihtiyaç olan düğüm sırasını belirleyen bölünme kuralı için farklı uygulamalar mevcuttur. Bu çalışmada seçilen bölünme kuralı ise Ortalama Kare Hatasıdır (Mean Squared Error- OKH). OKH, tahminlerimizin hedeften ne kadar saptığını gösteren ölçüyü oluşturmaktadır ve her bir öznitelik için hesaplanmaktadır. n adet veri içeren bir set için y hedef değerini, $\hat{y}$ ise yapılan ayırım ile üretilen tahmini temsil ederse şu şekilde ifade edilir:

$$OKH = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.1)$$

Bu teknikte, her bir öznitelik eğitim veri setinde artacak şekilde sıralanır ve sırasıyla her öz niteliğin her sırası için hedef etiket değerine göre OKH değeri hesaplanır. Bir başka deyişle sayıda n veri, k sayıda öznitelik içeren veri seti için toplam hesaplanan OKH sayısı 5.2 numaralı eşitlikte verilmiştir.

$$OKH \text{ Sayısı} = (n - 1) \times k \quad (5.2)$$

Hesaplanan tüm OKH değerlerine göre en iyi bölünme seçilerek düğümü oluşturur. Bu bölünme kuralı oluşan dallar için tekrarlanarak durdurma kuralına ulaşıncaya kadar devam eder. Bu çalışmada iki adet durdurma kuralı belirlenmiştir, birincisi düğümün saflığa yaklaşmasıdır. Saflığa yaklaşma için düğümün ikinci derece hata toleransı belirlenerek bu değere göre düğümün daha fazla bölünmeyip yaprak olarak kabul edileceği kararı verilir. Bu çalışma için hedef verilerin büyüklükleri gözetilerek ikinci derece hata toleransı 10^{-6} olarak belirlenmiştir. Düğüm başına ağırlıklı ortalama kare hatası, $10^{-6} \times \varepsilon$ 'nin altına düştüğünde, düğüm bölünmez, burada ε , karar ağacını büyütmeden önce düğüm özniteligi için hesaplanan OKH değeridir. İkinci durdurma kuralı ise minimum yaprak sayısıdır, eğer bir sonraki bölünme seçilen minimum yaprak boyutu değerinden küçük yapraklara sebep olursa bölünme gerçekleşmez ve bu düğüm yaprak olarak kabul edilir. Bu çalışmada minimum yaprak boyutu farklı değerler arasında aranmış ve maksimum verime sahip yaprak boyutu seçilmiştir. Modeller bir dalda bir ayırım olacak şekilde geliştirilmiştir.

5.2. Destek Vektör Regresyonu

Destek Vektör Regresyonu (DVR), hem sınıflandırma hem de regresyon amacıyla kullanılabilen denetimli bir makine öğrenme algoritmasıdır. Büyük veri setlerinde çok iyi performansa sahiptirler. DVR tekniği, geliştirilen modelin kabul edilebilir hata payını tanımlama esnekliği sunar. Büyük boyutlu veri setlerinde, örneklerle en iyi uyan hiperdüzlemi bularak model oluşturulur. Bu hiperdüzlemin bulunmasında yüksek boyutlarda işlem ihtiyacı olursa çekirdek fonksiyonları kullanılır. Belirlenecek ε marjin değeriyle hiperdüzlemin yanından iki düzlem daha oluşturulur, belirlenecek ceza değerleriyle oluşturulan modelin performansı değerlendirilir ve model yinelemeli şekilde iyileştirilir. Bu tez çalışmasında 1 marjin değeri ve 0,1 ceza değeri kullanılmıştır. DVR'nin adımları şu şekilde özetlenebilir:

Hiperdüzlemin denklemi, y 'nin hedef etiketleri, ω 'nin hiperdüzlemin normal vektörü, x 'in öznitelikleri, b 'nin ise eklenen biası ifade ettiği kabul edilirse şu şekilde ifade edilir:

$$\omega \cdot x_i + b = y_i \quad (5.3)$$

Yardımcı hiperdüzlemler de belirlenen ε marjın değeri şu şekilde ifade edilirler:

$$\omega \cdot x_i + b = y_i + \varepsilon, \quad \text{üst marjin için} \quad (5.4)$$

$$\omega \cdot x_i + b = y_i - \varepsilon, \quad \text{alt marjin için} \quad (5.5)$$

Marjinler vektör nokta çarpımı sayesinde $\frac{\varepsilon}{\omega}$ olarak da ifade edilebilir. DVR'de ana amaç marjini arttırmak olduğu için bu ifadenin artırılabilmesi için ω 'yi azaltmak gerekmektedir. ω 'nin azalması ile $\omega \cdot \omega$ ifadesi de azalacağı için hedef fonksiyonu şu şekilde yazılabilir:

$$\text{minimize et: } \frac{\|\omega\|^2}{2} \quad (5.6)$$

Bu kısıt göz önünde bulundurarak:

$$-\varepsilon \leq y_i - \omega \cdot x_i - b \leq \varepsilon \quad (5.7)$$


Bir diğer model belirleme kuralı ise belirlenen marjinin dışında kalan veri noktaları için ceza fonksiyonu atanmasıdır. Belirlenecek C parametresi ile marjinlerin dışında kalan noktalar için hata hesaplanır. Bu hata miktarının eklenmesiyle minimize edilecek fonksiyon şu şekilde ifade edilir:

$$\text{minimize et: } \frac{\|\omega\|^2}{2} + C \sum_{i=1}^n (\delta_i + \delta_i^*) \quad (5.8)$$

Bu kısıt göz önünde bulundurarak:

$$-\varepsilon - \delta_i^* \leq y_i - \omega \cdot x_i - b \leq \varepsilon + \delta_i \quad (5.9)$$

Burada δ_i üst marjine yakın olan ve marjin dışında kalan noktalar için uzaklığı temsil ederken, δ_i^* ise alt marjine yakın olan ve marjin dışında kalan noktalar için uzaklığı temsil ederler ve her ikisi de pozitif değerler alırlar. Şekil 5.2'de oluşan model gösterilmiştir.



Şekil 5.2. DVR modeli örneği [38]

Eş. 5.8 verilen problem, Eş. 5.9'daki kısıtlar göz önünde bulundurularak Lagrange fonksiyonu ile çözülür. Lagrange çözümü, [39]'de detaylıca anlatılmıştır. Bu çözüm ile elde edilen α_i ve α_i^* değerleri ile modeller ortaya çıkar. Oluşan model şu şekilde ifade edilebilir:

$$y = \sum_{i=1}^n (\alpha_i + \alpha_i^*) K(x_i, x) + b \quad (5.10)$$

Seçilen çekirdek fonksiyonuna göre $K(x_i, x)$ işlemi de değişmektedir. Bu tez çalışmasında şu çekirdek fonksiyonları kullanılmıştır:

$$\text{Doğrusal Çekirdek Fonksiyonu} : K(x_i, x) = x_i' x \quad (5.11)$$

$$\text{Gauss Çekirdek Fonksiyonu} : K(x_i, x) = e^{-||x_i - x||^2} \quad (5.12)$$


5.3. Torbalama Ağaçları

Torbalama Ağaçları (Bagging Trees) bu çalışmada kullanılan bir diğer makine öğrenmesi tekniğidir. “Bootstrap-Aggregation” yani Önyükleme-Toplama kelimelerinin birleşmesiyle üretilen “bagging” (torbalama) ifadesi metodun özeti gibidir. Torbalama yöntemi ile örnek alt kümesi kullanılarak birçok alt model oluşturulur ve bu modellerin çıktıları toplanarak sonuca ulaşılır.

Karar ağaçları modellerinin genellikle varyansı yüksektir bu da verideki ufak bir farklılığın modelde yüksek değişimi tetiklemesi anlamına gelmektedir. Bu yüzden bu topluluk tekniği ortaya çıkmıştır. Torbalama ağaçları varyansı şu şekilde düşürmektedir: n tane örnek içeren bir veri setinin varyansı σ olursa, bu veri setinin ortalamasının varyansı $\frac{\sigma}{n}$ olur. Eğer örnek sayısı artarken varyans değişmezse ortalamasının varyansı da azalmış olur. Torbalama tekniği de ağaç sayısını arttırıp tahminleriyle varyansı düşük bir model üretilmiş olur [40]. Bu çalışmada modelin geliştirme süreci şu şekildedir:

- İlk olarak veri seti kopyaları alınarak çoğaltılır.
- İkinci aşamada n tane örnek içeren veri seti için çalışılıyorsa, kopyalardan n tane veri seçilir ve ağaç geliştirilmeye başlanır.
- Ağaçlar geliştirilirken toplam öznitelik sayısının üçte biri kadar öznitelik rastgele seçilir ve ağaçlar o şekilde geliştirilir. Rastgele Orman adı verilen bu tekniğin torbalama yönteminin verimini arttırdığı görülmüştür.
- Bu şekilde oluşturulacak toplam ağaç sayısı ve bu ağaçlar için minimum yaprak boyutu belirlenir.
- Modelin çıktısı bu ağaçların ürettiği tahminlerin ortalaması şeklinde verilir [41].

Bu çalışmada geliştirilen modellerde minimum yaprak boyutu 8 olarak belirlenmiştir, ağaçlardaki dallar için bir ayrılma sayısı kısıdı konulmamıştır. Üretilcek toplam ağaç sayısı farklı değerler arasında en verimli sayıyı bulmak için aranmıştır. Şekil 5.3'te torbalama ağaçları modelinin genel şematiğini görülmektedir.




Şekil 5.3. Torbalama ağaçları şeması [42]

5.4. Derin Sinir Ağları


Nörobilimcilerin ortaya çıkardığı insan sinir hücrelerinin yapısından, bilgisayar bilimcilerin etkilenmesiyle bu teknik oluşmuştur. Bir başka deyişle insan öğrenimi için kullanılan biyolojik sinir ağları yerine makine öğrenimi için kullanılan yapay sinir ağları metodu ortaya çıkmıştır. Bu metot günümüzde yaygın olarak kullanılan bir makine öğrenmesi tekniğidir.

Yapay Sinir Ağları, girdi katmanı, ara katmanlar (gizli katmanlar) ve sonuç katmanı olmak üzere üç ana parçadan oluşurken ara katman sayısının birden fazla olması durumunda Derin Sinir Ağları olarak nitelendirilebilirler. Girdi katmanı verinin modele alındığı katmandır ve bir işlem yapılmadan veri ara katmanlardaki nöronlara iletilir. Ara katmanlardaki nöronların her bir girişi için atanan ağırlık değerleri ve bias değerleri mevcuttur ve bu değerler gelen girdiyle birlikte nöronun üreteceği çıktıyı belirler. Ara katmanlarda üretilen değerler sonuç katmanına ulaşıncaya kadar sırasıyla bir sonraki katmana yine aynı mantık işletilerek iletilirler. Sonuç katmanında tüm işlemlerin ürettiği değerler neticesinde bir çıktı verilir. Şekil 5.4'te üç ara katmanı olan bir sinir ağı modeli verilmiştir.



Şekil 5.4. Üç ara katmanı olan bir derin sinir ağı örneği [43]

Ara katmanlardaki nöronların ağırlıkları, biası ve gelen girişler üretilen çıktının doğruluğu için direkt etkilidir. Herhangi bir ara katmanda verinin işlenmesi Şekil 5.5'te verilmiştir:



Şekil 5.5. Ara katmandaki bir nöronun veri işlenmesi diyagramı [44]

Şekilde verilen R adet girdisi olan ve n çıktısı üreten toplama fonksiyonu şu şekilde formülize edilebilir:

$$n = (\sum_{i=1}^R w_i p_i) + b \quad (5.13)$$

Burada üretilen n değeri daha sonrasında bir aktivasyon fonksiyonuna girmektedir. Bu çalışmada aktivasyon fonksiyonu tan-sigmoid seçilmiştir. Tan-sigmoid fonksiyonu giriş değerlerini $[-1,1]$ aralığında normalize eder ve bu değerlere bağlı olarak $[-1,1]$ aralığında bir çıkış üretir. Bu işlemi şu fonksiyon ile gerçekleştirir:

$$\text{tansig}(n) = \frac{2}{(1+e^{-2n})} + 1 \quad (5.14)$$

Bu fonksiyonun çıkışı da diğer katmanlardaki nöronlara giriş olarak iletilir. Bu işlemlerde kullanılan ağırlık ve bias değerleri ilk olarak verimli olmayacaklar ve başarılı bir sonuç vermeyeceklerdir. Üretilen sonuca göre iyileştirme işlemlerine geri yayılım (backpropagation) denmektedir. Bu çalışmada ise bu değerleri yinelemeli şekilde iyileştirmek için “Momentum ve uyarlanabilir öğrenme oranı geri yayılımı ile gradyan azalma” (Gradient descent with momentum and adaptive learning rate backpropagation) tekniği kullanılmıştır.

Gradyan Azalma tekniğinin temel amacı mutlak minimum değerine ulaşmaktır, bu makine öğrenmesi için kullanıldığında minimum hataya ulaşmak denebilir. Bu minimum noktasına ulaşmak için parametrelerle oynamak gerekmektedir. Klasik Gradyan Azalma tekniğinde model, rastgele parametrelerden başlar, öğrenme katsayısı (learning rate) kullanılarak parametreler yinelemeli şekilde iyileştirilir. Basitçe anlatmak gerekirse tahmini şu şekilde yapan bir model için:

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 \quad (5.15)$$

Tahminle gerçek değer arasındaki farkı bularak parametrelerin bulunmasını sağlayan fonksiyona maliyet fonksiyonu denir ve şu şekilde yazılır:

$$J(\theta) = \frac{1}{2s} \sum_{i=1}^s (h_{\theta}(x^{(i)}) - y^{(i)})^2 \quad (5.16)$$

Buradaki s örnek sayısı, y ise etiket değeridir. Maliyet fonksiyonun θ parametrelerine göre türevi alınarak minimum değeri bulunmaya çalışılır:

$$\theta_0 := \theta_0 - \alpha \frac{\partial}{\partial \theta_0} J(\theta) \quad (5.17)$$

$$\theta_1 := \theta_1 - \alpha \frac{\partial}{\partial \theta_1} J(\theta) \quad (5.18)$$

Burada α olarak simgelenen sembol öğrenme katsayısını temsil eder ve parametrelerin her yineleme periyodunda güncellenmesini sağlar. Klasik gradyan azalma tekniğinden farklı olarak momentum ve uyarlanabilir öğrenme oranı ile gradyan azalma tekniğinde öğrenme katsayısı sabit değildir ve momentum katsayısı mevcuttur. Böylelikle sabit öğrenme katsayısının getirmiş olduğu doğruluktan çok sapma veya hızlı ilerleyememe gibi problemler ortadan kalmış olur. Klasik gradyan azalma fonksiyonunu şu şekilde ifade edersek:

$$\theta := \theta - \alpha \frac{\partial}{\partial \theta} J(\theta) \quad (5.19)$$

Momentum ve uyarlanabilir öğrenme oranı ile gradyan azalma tekniği m momentum katsayısı ile şu şekilde ifade edilebilir:

$$\theta := m\theta - m\alpha \frac{\partial}{\partial \theta} J(\theta) \quad (5.20)$$

Bu çalışmada öğrenme katsayısının uyarlanması şu şekilde sağlanmıştır: 0,1 öğrenme katsayısından başlanarak her periyotta öğrenme katsayısı 1,05 ile çarpılarak arttırılmış, eğer hata oranı 1,04 kattan fazla artmamışsa yeni ağırlıklar ve biaslar kullanılmıştır. Eğer hata oranı 1,04 kattan fazla artmışsa yeni değerler kullanılmamış ve öğrenme katsayısı 0,7 ile çarpılarak azaltılmıştır. Momentum katsayısı 0,9 alınmıştır ve ortalama kare hata değeri 10^{-5} 'nin altına ininceye kadar devam edilmiştir. Çalışmada ayrıca ara katman sayısı farklı değerler arasında taranmış ve en verimli değer kullanılmıştır.

6. DENEYSEL ÇALIŞMALAR

Deneyler, 8 GB Ram'e sahip Intel(R) Core(TM) i7-4702MQ CPU @ 2.20GHz bir bilgisayarda yüklü Matlab 2020b versiyonu kullanılarak gerçekleştirilmiştir. Makine öğrenmesi modellerini eğitmek ve test etmek için X-Plane ile gerçekleştirilen uçuşlardan 36104 adet örnek içeren veri seti kullanılmıştır. Bu veri setinin %20'si, yani rastgele seçilen 7221 örnek test için ayrılmıştır. Model oluşturmak için eğitim veri seti olarak 28883 örnek kullanılmıştır.

Makine öğrenmesi modellerinin ayarlanacak parametrelerinin belirlenmesi için bekletme doğrulaması kullanılmıştır. Bekletme doğrulama yöntemi büyük veri setleri için uygun bir yöntemdir. Bu çalışmadaki eğitim veri setinden rastgele seçilen %20'lik kısım doğrulama kısmını oluşturmaktadır ve eğitim veri setinden ayrılmıştır. Doğulamada kullanılan toplam örnek sayısı 5777'tir. Bekletme doğrulaması başarımlı ölçütü olarak Eş. 5.1'te verilen ortalama kare hata kriteri kullanılmıştır.

Tez çalışmasında Başlık 3'te de belirtildiği gibi hücum açısı, yakıt akış hızı ve küresel konumlama sensörlerindeki hatalar tespit edilmeye çalışılmıştır. Bu yüzden geliştirilen Karar Ağaçları, Destek Vektör Regresyonu, Torbalama Ağaçları ve Derin Sinir Ağları metodlarıyla bu sensörlerin verileri tahmin edilmeye çalışılmıştır. Deney aşamaları şu şekilde özetlenebilir:

- 1- Öncelikle bekletme doğrulaması ile hücum açısı, yakıt akış hızı ve enlem-boylam değişim hızlarının her biri için:
 - Karar Ağacı için minimum yaprak boyutu değiştirilerek her bir sensör için en verimli Karar Ağacı modeli,
 - Destek Vektör Regresyonu için çekirdek değiştirilirse her bir sensör için en verimli Destek Vektör Regresyonu modeli,
 - Torbalama Ağaçları için öğrenen ağaç sayısı değiştirilerek her bir sensör için en verimli Torbalama Ağaçları modeli,
 - Derin Sinir Ağları için ara katman sayısı değiştirilerek her bir sensör için en verimli Derin Sinir Ağları modeli bulunmuştur.

- 2- Daha sonra her bir sensör verisi için her metodun en verimli modelleri test veri setinde denenmiştir ve hücum açısı, yakıt akış hızı ve enlem-boylam değişim hızları için ayrı ayrı en başarılı makine öğrenmesi modeli bulunmuştur.
- 3- Modellerin geliştirildiği ve test edildiği uçuş veri setlerinden bağımsız olarak üç adet bağımsız uçuş verisi alınmış ve bu üç uçuş verisine:
 - hücum açısı için 22 derecelik sabit hata ve son değerde takılı kalma hatası,
 - yakıt akış hızı için saatte 10 bin pound yakıt sızıntısı ve analog sensörle iletişimin kopması (sıfıra düşme hatası),
 - küresel konumlama sistemi için ise gürültülü veri durumları eklenmiştir.
- 4- İkinci adımda bulunan her bir sensör için en başarılı makine öğrenmesi modeli kullanılarak üçüncü adımdaki hatalar tespit edilmiştir ve düzeltilmiştir.
- 5- Son olarak hem yakıt akış hızı sensörünün hem de hücum açısı algılayıcısı sensörünün birlikte bozulduğu bir başka deyişle çoklu sensör hatalarının olduğu durumlar için geliştirilen modellerin başarımı test edilmiştir.

6.1. Hücum Açısı Verileri için Model Seçimi

Eğitim veri seti incelendiğinde hücum açısı için -5 ile 28 derece arasında değişen değerlerde verilerin bulunduğu görülmektedir. Modeller geliştirilirken Çizelge 4.1’de yer alan hücum açısı verisi hariç tutularak 26 sensör verisinin tamamı hücum açısını tahmin etmek için öznitelik olarak kullanılmıştır.

6.1.1. Hücum açısı için karar ağacı modeli

Hücum açısı algılayıcısı karar ağacı modeli Bölüm 5.1’te verildiği gibi CART tekniği kullanılarak ortalama kare hata bölünme kuralıyla Matlab kütüphanesi kullanılarak üretilmişlerdir. Minimum yaprak boyutu bekletme doğrulaması ile 4, 8 ve 16 değerleri arasında aranmış ve en başarılı model bulunmaya çalışılmıştır. Çizelge 6.1’de değişen minimum yaprak boyutu değerlerine göre geliştirilen modellerin eğitim ve doğrulama veri setlerindeki OKH’ye göre performansları bulunmaktadır.

Çizelge 6.1. Hücüm açısı-farklı min. yaprak boyutu ile geliştirilen modeller

Ayarlanan Minimum Yaprak Boyutu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
4	0,0251	0,0856
8	0,0525	0,0977
16	0,0954	0,1317

Minimum yaprak boyutu 4 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.1.2. Hücüm açısı için destek vektör regresyonu modeli

Hücüm açısı algılayıcısı DVR modeli Bölüm 5.2’te verilen marjin ve ceza değerleriyle Matlab “fitrsvm” fonksiyonu kullanılarak üretilmişlerdir. Seçilecek çekirdek fonksiyonu bekletme doğrulaması ile doğrusal ve Gauss fonksiyonlar arasında aranmış ve başarılı model bulunmaya çalışılmıştır. Çizelge 6.2’de geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.2. Hücüm açısı-farklı çekirdek fonksiyonu ile geliştirilen modeller

Çekirdek Fonksiyonu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
Doğrusal	1,4666	1,5191
Gauss	2,5539	3,4088

Doğrusal çekirdek fonksiyonu kullanılarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde daha az hataya sahip olunmuştur.

6.1.3. Hücüm açısı için torbalama ağaçları modeli

Hücüm açısı algılayıcısı Torbalama Ağaçları modeli geliştirilirken her bir ağaç için ayarlanan minimum yaprak boyutu 8 olarak seçilmiş ve Matlab’da yer alan “Ensemble Bagging Trees” kütüphanesi kullanılmıştır. Seçilecek toplam öğrenme ağacı sayısı ise bekletme doğrulaması ile 10, 20 ve 40 değerleri arasında aranmış ve geliştirilen modeller karşılaştırılmıştır. Çizelge 6.3’te geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.3. Hücum açısı-farklı öğrenme ağaç sayısı ile geliştirilen modeller

Öğrenme Ağacı Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
10	0,0417	0,0941
20	0,0262	0,0596
40	0,0225	0,0557

Öğrenme ağacı sayısı 40 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.1.4. Hücum açısı için derin sinir ağları modeli

Hücum açısı algılayıcısı Derin Sinir Ağları modeli, momentum ve uyarlanabilir öğrenme oranı geri yayılımı ile gradyan azalma metodu ve bölüm 5.4'te verilen parametreler kullanılarak Matlab kütüphanesi ile geliştirilmiştir. Belirlenecek ara katman sayısı da bekletme doğrulaması ile 5, 10 ve 15 değerleri arasında aranmış ve en başarılı model bulunmaya çalışılmıştır. Çizelge 6.4'te geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.4. Hücum açısı-farklı ara katman sayısı ile geliştirilen modeller

Ara Katman Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
5	2,2853	2,3848
10	3,9837	4,2764
15	2,7254	2,9713

Ara katman sayısı 5 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.2. Yakıt Akış Hızı Verileri için Model Seçimi

Yakıt akışı hızı eğitim veri setinde incelendiğinde saatte 850 ile 40350 pound arasında değişen değerlerde veriler görülmektedir. Modeller geliştirilirken Çizelge 4.1'de yer alan yakıt akış hızı haricindeki 26 sensör verisinin tamamı öz nitelik olarak kullanılmıştır.

6.2.1. Yakıt akış hızı için karar ağacı modeli

Bölüm 5.1’de anlatıldığı gibi model geliştirilmiş, en verimli minimum yaprak boyutu bekletme doğrulaması ile 4, 8 ve 16 değerleri arasında taranmıştır. Çizelge 6.5’te değişen minimum yaprak boyutu değerlerine göre geliştirilen modellerin eğitim ve doğrulama veri setlerindeki OKH’ye göre performansları bulunmaktadır.

Çizelge 6.5. Yakıt akış hızı-farklı min. yaprak boyutu ile geliştirilen modeller

Ayarlanan Minimum Yaprak Boyutu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
4	$7,39 \times 10^4$	$2,06 \times 10^5$
8	$1,29 \times 10^5$	$2,08 \times 10^5$
16	$2,4288 \times 10^5$	$2,97 \times 10^5$

Minimum yaprak boyutu 4 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.2.2. Yakıt akış hızı için destek vektör regresyonu modeli

Bölüm 6.1.2’de anlatıldığı gibi model oluşturulmuştur ve seçilecek çekirdek fonksiyonu aynı şekilde aranmış ve başarılı model bulunmaya çalışılmıştır. Çizelge 6.6’da geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.6. Yakıt akış hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller

Çekirdek Fonksiyonu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
Doğrusal	$1,81 \times 10^7$	$1,82 \times 10^7$
Gauss	$6,28 \times 10^7$	$6,27 \times 10^7$

Doğrusal çekirdek fonksiyonu kullanılarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde daha az hataya sahip olunmuştur.

6.2.3. Yakıt akış hızı için torbalama ağaçları modeli

Bölüm 6.1.3'te anlatıldığı gibi model oluşturulmuştur ve seçilecek toplam öğrenme ağacı sayısı da aynı şekilde aranmıştır. Çizelge 6.7'te geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.7. Yakıt akış hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller

Öğrenme Ağacı Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
10	$5,93 \times 10^4$	$1,1 \times 10^5$
20	$5,21 \times 10^4$	$9,67 \times 10^4$
40	$4,76 \times 10^4$	$8,93 \times 10^4$

Öğrenme ağacı sayısı 40 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.2.4. Yakıt akış hızı için derin sinir ağları modeli

Bölüm 6.1.4'te anlatıldığı gibi model oluşturulmuştur ve seçilecek ara katman sayısı 5, 10 ve 15 arasında aranmıştır. Çizelge 6.8'te geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.8. Yakıt akış hızı-farklı ara katman sayısı ile geliştirilen modeller

Ara Katman Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
5	$2,39 \times 10^6$	$2,59 \times 10^6$
10	$3,70 \times 10^6$	$3,74 \times 10^6$
15	$2,15 \times 10^7$	$2,12 \times 10^7$

Ara katman sayısı 5 ayarlanarak geliştirilen modelde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.3. Enlem ve Boylam Değişim Hızı Verileri için Model Seçimi

Enlem ve boylamın değişim hızları enlem/boylam verileri ve zaman verisi kullanılarak oluşturulmuşlardır. Eğitim veri setinde enlem değişim hızı saniyede -0,0033 ile 0,0031

derece arasında, boylam değişim hızı ise saniyede -0,0039 ile 0,0042 arasında değişmektedir. Enlem değişim hızını ve boylam değişim hızını tahmin eden farklı modeller oluşturulmuştur. Modeller geliştirilirken Çizelge 4.1’de yer alan enlem değişim hızı ve boylam değişim hızı verileri haricindeki 25 sensör verisinin tamamı öznitelik olarak kullanılmıştır.

6.3.1. Enlem ve boylam değişim hızları için karar ağacı modeli

Bölüm 6.1.1’de geçen şekilde modeller geliştirilmiştir. Çizelge 6.9’da ve 6.10’da değişen minimum yaprak boyutu değerlerine göre geliştirilen enlem değişim hızı ve boylam değişim hızı modellerinin eğitim ve doğrulama veri setlerindeki OKH’ye göre performansları bulunmaktadır.

Çizelge 6.9. Enlem değişim hızı-farklı min. yaprak boyutu ile geliştirilen modeller

Ayarlanan Minimum Yaprak Boyutu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
4	$1,36 \times 10^{-9}$	$3,19 \times 10^{-9}$
8	$1,63 \times 10^{-9}$	$3,26 \times 10^{-9}$
16	$2,22 \times 10^{-9}$	$3,55 \times 10^{-9}$

Çizelge 6.10. Boylam değişim hızı-farklı min. yaprak boyutu ile geliştirilen modeller

Ayarlanan Minimum Yaprak Boyutu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
4	$1,94 \times 10^{-9}$	$3,52 \times 10^{-9}$
8	$2,32 \times 10^{-9}$	$3,76 \times 10^{-9}$
16	$3,26 \times 10^{-9}$	$4,71 \times 10^{-9}$

Minimum yaprak boyutu 4 ayarlanarak geliştirilen her iki model de hem eğitim verisinde hem de doğrulama verisinde en az hataya sahiptir.

6.3.2. Enlem ve boylam değişim hızları için destek vektör regresyonu modeli

Bölüm 6.1.2’de anlatıldığı gibi modeller oluşturulmuştur ve seçilecek çekirdek fonksiyonu aynı şekilde aranmış ve başarılı modeller bulunmaya çalışılmıştır. Çizelge 6.11’de ve 6.12’de geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.11. Enlem değişim hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller

Çekirdek Fonksiyonu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
Doğrusal	$2,02 \times 10^{-6}$	$1,96 \times 10^{-6}$
Gauss	$2,02 \times 10^{-6}$	$1,96 \times 10^{-6}$

Çizelge 6.12. Boylam değişim hızı-farklı çekirdek fonksiyonu ile geliştirilen modeller

Çekirdek Fonksiyonu	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
Doğrusal	$5,31 \times 10^{-6}$	$5,47 \times 10^{-6}$
Gauss	$5,31 \times 10^{-6}$	$5,47 \times 10^{-6}$

Burada çekirdek fonksiyonu değişse de hem enlem değişim hızı modeli hem de boylam değişim hızı modeli için aynı OKH değerlerine ulaşılmıştır.

6.3.3. Enlem ve boylam değişim hızları için torbalama ağaçları modeli

Bölüm 6.1.3'te anlatıldığı gibi modeller oluşturulmuştur ve seçilecek toplam öğrenme ağacı sayısı da aynı şekilde aranmıştır. Çizelge 6.13'te ve 6.14'te geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.13. Enlem değişim hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller

Öğrenme Ağacı Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
10	$2,17 \times 10^{-9}$	$4,10 \times 10^{-9}$
20	$1,52 \times 10^{-9}$	$2,83 \times 10^{-9}$
40	$1,31 \times 10^{-9}$	$2,42 \times 10^{-9}$

Çizelge 6.14. Boylam değişim hızı-farklı öğrenme ağaç sayısı ile geliştirilen modeller

Öğrenme Ağacı Sayısı	Eğitim Veri Seti OKH değeri	Doğrulama Veri Seti OKH değeri
10	$2,05 \times 10^{-9}$	$3,74 \times 10^{-9}$
20	$1,83 \times 10^{-9}$	$3,16 \times 10^{-9}$
40	$1,76 \times 10^{-9}$	$3,05 \times 10^{-9}$

Öğrenme ağacı sayısı 40 ayarlanarak geliştirilen modellerde hem eğitim verisinde hem de doğrulama verisinde en az hataya sahip olunmuştur.

6.3.4. Enlem ve boylam deęişim hızları için derin sinir aęları modeli

Bölüm 6.1.4'te anlatıldığı gibi modeller oluşturulmuştur ve seçilecek ara katman sayısı 5, 10 ve 15 arasında aranmıştır. Çizelge 6.15'te ve 6.16'da geliştirilen modellerin performansları bulunmaktadır.

Çizelge 6.15. Enlem deęişim hızı-farklı ara katman sayısı ile geliştirilen modeller

Ara Katman Sayısı	Eęitim Veri Seti OKH deęeri	Doęrulama Veri Seti OKH deęeri
5	$4,85 \times 10^{-6}$	$4,67 \times 10^{-6}$
10	$3,52 \times 10^{-6}$	$3,51 \times 10^{-6}$
15	$4,36 \times 10^{-6}$	$4,25 \times 10^{-6}$

Çizelge 6.16. Boylam deęişim hızı-farklı ara katman sayısı ile geliştirilen modeller

Ara Katman Sayısı	Eęitim Veri Seti OKH deęeri	Doęrulama Veri Seti OKH deęeri
5	$7,32 \times 10^{-6}$	$7,44 \times 10^{-6}$
10	$3,20 \times 10^{-6}$	$3,23 \times 10^{-6}$
15	$5,35 \times 10^{-6}$	$5,41 \times 10^{-6}$

Ara katman sayısı 10 ayarlanarak geliştirilen modeller hem enlem deęişim hızı hem de boylam deęişim hızı için en az hataya sahip olunan modeller olmuşlardır.

6.4. Test Verisi ile En Başarılı Öğrenme Metotlarının Bulunması

Çalışmanın bu kısmında her bir sensör için geliştirilen makine öğrenmesi metotlarının en verimli modellerinin test verisinde performansı karşılaştırılmış ve her sensör için nihai model bulunmuştur.


6.4.1. Hücum açısı verisi için metotların karşılaştırılması

Hücum Açısı verisinin tahmini için oluşturulan Karar Ağacı modellerinden en başarılısı minimum yaprak boyutu 4 iken, Torbalama Ağaçları modellerinden en başarılısı ağaç sayısı 40 iken ve derin sinir aęları modellerinden en başarılısı ara katman sayısı 10 iken ortaya çıkan modeller olmuşlardır. Test veri setine bu modeller uygulandığı zaman Çizelge 6.17 ortaya çıkmıştır.

Çizelge 6.17. Test verisi ile hücum açısı için metot karşılaştırılması

Metot	Test Veri Seti OKH değeri
Karar Ağacı	0,1059
Destek Vektör Regresyonu	1,5032
Torbalama Ağaçları	0,0537
Derin Sinir Ağları	2,2710

Torbalama Ağaçları test verisi ile en az hatayı üreten model olarak ortaya çıkmıştır. Test verisi hücum açısına göre artan şekilde sıralanmıştır ve modelin tahminlerinin grafiği Şekil 6.1’de verilmiştir.



Şekil 6.1. Hücum açısı için en iyi modelin test verisi performansı


6.4.2. Yakıt akış hızı verisi için metotların karşılaştırılması

Yakıt Akış Hızı verisinin tahmini için oluşturulan Karar Ağacı modellerinden en başarılısı minimum yaprak boyutu 4 iken, DVR modellerinden en başarılısı doğrusal çekirdek fonksiyonu iken, Torbalama Ağaçları modellerinden en başarılısı ağaç sayısı 40 iken ve derin sinir ağları modellerinden en başarılısı ara katman sayısı 5 iken ortaya çıkan modeller olmuşturlardır. Test veri setine bu modeller uygulandığı zaman Çizelge 6.18 ortaya çıkmıştır.

Çizelge 6.18. Test verisi ile yakıt akış hızı için metot karşılaştırılması

Metot	Test Veri Seti OKH değeri
Karar Ağacı	$1,74 \times 10^5$
Destek Vektör Regresyonu	$1,65 \times 10^7$
Torbalama Ağaçları	$9,84 \times 10^4$
Derin Sinir Ağları	$2,31 \times 10^6$

Torbalama Ağaçları yakıt akış hızı için de en az hatayı üreten model olarak ortaya çıkmıştır. Test verisi yakıt akış hızına göre artan şekilde sıralanmıştır ve modelin tahminlerinin grafiği Şekil 6.2’de verilmiştir.



Şekil 6.2. Yakıt akış hızı için en iyi modelin test verisi performansı


6.4.3. Enlem ve boylam değişim hızı verileri için metotların karşılaştırılması

Enlem ve Boylam Değişim Hızları tahmini için oluşturulan modellerin performansında hem enlem hem boylam için aynı özellikteki modeller daha başarılı olmuşlardır. Karar Ağacı modellerinden en başarılısı minimum yaprak boyutu 4 iken, Torbalama Ağaçları modellerinden en başarılısı ağaç sayısı 40 iken ve derin sinir ağları modellerinden en başarılısı ara katman sayısı 10 iken ortaya çıkan modeller olmuşlardır. DVR modelleri aynı sonuçları verdiği için daha hızlı sonuç veren Gauss DVR tercih edilmiştir. Test veri setine

bu modeller uygulandığı zaman Çizelge 6.19 ortaya çıkmıştır. Enlem değişim hızı tahmininde de boylam değişim hızı tahmininde de en başarılı model Torbalama Ağaçları olarak bulunmuştur.


Çizelge 6.19. Test verisi ile enlem ve boylam değişimi için metot karşılaştırılması

Metot	Enlem Değişimi Test Veri Seti OKH değeri	Boylam Değişimi Test Veri Seti OKH değeri
Karar Ağacı	$2,77 \times 10^{-9}$	$3,82 \times 10^{-9}$
Destek Vektör Regresyonu	$1,98 \times 10^{-6}$	$5,35 \times 10^{-6}$
Torbalama Ağaçları	$2,36 \times 10^{-9}$	$2,97 \times 10^{-9}$
Derin Sinir Ağları	$3,50 \times 10^{-6}$	$5,54 \times 10^{-6}$



Şekil 6.3. Enlem değişim hızı için en iyi modelin test verisinde performansı

Boylamlardan farklı olarak iki enlem derecesi arasındaki mesafe farkı sabit olduğu için, enlem değişim hızında modelin performansı daha iyi olduğu için görülmektedir. Şekil 6.3'te enlem değişim hızı grafiği görülmektedir. Şekil 6.4'te ise boylam değişim hızı modelinin performansı verilmiştir.




Şekil 6.4. Boylam değişim hızı için en iyi modelin test verisinde performansı

6.5. Bağımsız Sensör Hatalı Uçuş Verileri ile Model Performansı

Çalışmanın bu kısmında model geliştirme ve en iyi modeli bulmak için gerçekleştirilen uçuşlardan bağımsız olarak üç test uçuşu gerçekleştirilmiştir. Test uçuşları sırasıyla 2242, 1646 ve 1087 örnek içermektedir. Bu uçuşlarda sensörlere Bölüm 3'te bahsedilen gerçek dünyada rastlanan hatalar eklenmiştir. Daha sonrasında her bir sensör için bulunan en iyi model ile sensör hatası tespit edilmiş ve düzeltme uygulanmıştır. Hatalı veri uçuşun bir noktasından itibaren gerçekleşse bile tüm uçuş boyunca yapılan tahminlerin toplam hata miktarı daha az olarak ortaya çıkmıştır.

6.5.1. Hücum açısı hata tespiti

Gerçekleştirilen üç test uçuşu için hücum açısı sağlıklı veri üretmiş ve gerçek dünya sensör hataları daha sonrasında elle eklenmiştir. Eklenen hatalar sabit 22 derecelik sapma hatası ve son değerde takılı kalma hatalarıdır. Her iki hata da uçuşların yarısında gerçekleşmiş sırasıyla 1100'üncü, 900'üncü ve 550'nci veri noktasından sonra eklenmişlerdir. Şekil 6.5'te birinci test uçuşu için bias hatasının oluşumu örnek olarak gösterilmiştir.




Şekil 6.5. Test uçuş-1 için hücum açısı sensörü bias hatası oluşumu

Hücum açısı sensöründe gerçekleşen sabit 22 derecelik bir hatanın veriyi ne kadar etkilediği Şekil 6.5'te görülmektedir. Bu test uçuşu ve diğer iki test uçuşu hücum açısı değerleri diğer sensör verileri kullanılarak torbalama ağaçları modeliyle tahmin edilmiş ortaya Çizelge 6.20'deki tablo çıkmıştır.


Çizelge 6.20. Bağımsız uçuş test verileriyle yapılan hücum açısı tahminleri

Uçuş	Bias Hatalı Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	247	0,7252
Test Uçuş-2	220	0,5936
Test Uçuş-3	240	0,9080

Çizelge 6.20'de de görüldüğü üzere geliştirilen modelin OKH değeri oldukça düşüktür. Geliştirilen modelin bias hatalı üç uçuştaki performansları Şekil 6.6, 6.7 ve 6.8'de verilmiştir.




Şekil 6.6. Test uçuş-3'te oluşan bias hatası ve model tahminleri



Şekil 6.7. Test uçuş-2'de oluşan bias hatası ve model tahminleri

Şekil 6.6, 6.7 ve 6.8'de görüldüğü üzere model bias hata içeren hücum açısını tahmin etmek için oldukça başarılıdır.

İkinci hücum açısı sensör hatası ise son değerde takılı kalma hatasıdır. Şekil 6.9'da üçüncü test uçuşu için son değerde takılı kalma hatasının oluşumu örnek olarak gösterilmiştir.




Şekil 6.8. Test uçuş-3 için hücum açısı sensörü takılı kalma hatası oluşumu

Hücum açısı sensöründe gerçekleşen son değerde kalma hatasının veriye etkisi üçüncü test uçuşu için Şekil 6.9’da verilmiştir. Bu test uçuşu ve diğer iki test uçuşu hücum açısı değerleri diğer sensör verileri kullanılarak torbalama ağaçları modeliyle tahmin edilmiş ortaya Çizelge 6.21’deki tablo çıkmıştır.


Çizelge 6.21. Bağımsız uçuş test verileriyle yapılan hücum açısı tahminleri

Uçuş	Son Değer Hatası Oluşan Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	3,95	0,7252
Test Uçuş-2	2,63	0,5936
Test Uçuş-3	10,41	0,9080


Geliştirilen modelin bias hatalı üç uçuştaki performansları Şekil 6.10, 6.11 ve 6.12’de verilmiştir.



Şekil 6.9. Test uçuş-1’de oluşan son değer hatası ve model tahminleri



Şekil 6.10. Test uçuş-3’te oluşan son değer hatası ve model tahminleri




Şekil 6.11. Test uçuş-2'de oluşan son değer hatası ve model tahminleri

Üç test uçuşu da incelendiği zaman model tahminlerinin birkaç uç nokta haricinde 3 dereceden fazla yapmadığı ve 3 derece hata yaptığı durumlarda bile bu hatanın yaklaşık bir saniyede ortadan kalktığı görülmektedir. Modeller için 1 derecelik hata payını 25 periyot yani yaklaşık 5 saniye aşarsa hata vardır şeklinde bir kural koyulduğunda bias hatasında birinci ve ikinci uçuş için hata oluştuğundan tam 5 saniye sonra hatanın farkedildiği, üçüncü uçuşta ise daha öncesinde bir yanlış alarm verilmesine rağmen hata durumunda da 5 saniyede doğru şekilde hatanın tespit edildiği görülmüştür. Aynı şekilde son değerde takılı kalma hatası için ilk uçuş için 5,5 saniyede hatayı tespit etmiş, ikinci uçuşun hata oluşma noktasından ötürü hata oluştuğundan yaklaşık 50 saniye sonra hata tespit edilebilmiştir, son uçuşta yine hata oluştuğundan 9,5 saniye sonra hata tespit edilebilmiştir.

6.5.2. Yakıt akış hızı hata tespiti

Gerçekleştirilen üç test uçuşu için yakıt akış hızı verisinde bir hata yokken ve gerçek dünya sensör hataları daha sonrasında elle eklenmiştir. Yakıt sızıntısı durumunda oluşabilecek saatte 10.000 pound yakıt akışında bias değeri ve analog sensörle iletişimin kopması durumunda oluşan sıfıra düşme hatası eklenen hatalardır. Her iki hata da uçuşların yarısında gerçekleşmiş sırasıyla 1100'üncü, 900'üncü ve 550'nci veri noktasından sonra eklenmişlerdir. Şekil 6.13'te birinci test uçuşu için yakıt sızıntısı hatasının oluşumu örnek olarak gösterilmiştir.




Şekil 6.12. Test uçuş-1 için yakıt sızıntısı hatası oluşumu

Yakıt akış hızı sensöründe saatte on bin pound yakıt sızıntısının veriyi ne kadar etkilediği Şekil 6.13'te görülmektedir. Bu test uçuşu ve diğer iki test uçuşu yakıt akış hızı değerleri diğer sensör verileri kullanılarak torbalama ağaçları modeliyle tahmin edilmiş ortaya Çizelge 6.22'deki tablo çıkmıştır.


Çizelge 6.22. Bağımsız uçuş test verileriyle yapılan yakıt akış hızı tahminleri

Uçuş	Sızıntı Hatası Oluşan Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	$5,1 \times 10^7$	$2,86 \times 10^6$
Test Uçuş-2	$4,54 \times 10^7$	$1,03 \times 10^6$
Test Uçuş-3	$4,95 \times 10^7$	$7,38 \times 10^6$


Çizelge 6.22'de de görüldüğü üzere geliştirilen modelin OKH değeri, hatalı sensör verisi ile karşılaştırıldığı zaman oldukça düşük kalmaktadır. Geliştirilen modelin yakıt sızıntısı varken olan üç uçuştaki performansları Şekil 6.14, 6.15 ve 6.16'da verilmiştir.



Şekil 6.13. Test uçuş-1’de oluşan yakıt sızıntısı hatası ve model tahminleri




Şekil 6.14. Test uçuş-3’te oluşan yakıt sızıntısı hatası ve model tahminleri



Şekil 6.15. Test uçuş-2'de oluşan yakıt sızıntısı hatası ve model tahminleri

Şekil 6.14, 6.15 ve 6.16'da görüldüğü üzere model yakıt sızıntısı hatası içeren durumda üretilen yakıt akış hızı sensör verisini tahmin etmek için oldukça başarılıdır.

Bir diğer yakıt akış sensör hatası ise iletişimin kopması yani sıfıra düşme hatasıdır. Şekil 6.17'de üçüncü test uçuşu için sıfıra düşme hatasının oluşumu örnek olarak gösterilmiştir.




Şekil 6.16. Test uçuş-3 için sıfıra düşme hatası oluşumu

Yakıt akış hızı sensöründe gerçekleşen sıfıra düşme hatasının veriye etkisi üçüncü test uçuşu için Şekil 6.17’de verilmiştir. Bu test uçuşu ve diğer iki test uçuşunun yakıt akış hızı değerleri diğer sensör verileri kullanılarak torbalama ağaçları modeliyle tahmin edilmiş ortaya Çizelge 6.23’deki tablo çıkmıştır.


Çizelge 6.23. Bağımsız uçuş test verileriyle yapılan yakıt akışı tahminleri

Uçuş	Sıfıra Düşme Hatası Oluşan Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	$7,88 \times 10^7$	$2,86 \times 10^6$
Test Uçuş-2	$5,27 \times 10^6$	$1,03 \times 10^6$
Test Uçuş-3	$4,98 \times 10^8$	$7,38 \times 10^6$


Geliştirilen modelin sıfıra düşme hatalı üç uçuştaki performansları Şekil 6.18, 6.19 ve 6.20’de verilmiştir.



Şekil 6.17. Test uçuş-1’de oluşan sıfıra düşme hatası ve model tahminleri



Şekil 6.18. Test uçuş-3'te oluşan sıfıra düşme hatası ve model tahminleri




Şekil 6.19. Test uçuş-2'de oluşan sıfıra düşme hatası ve model tahminleri

Üç test uçuşu da incelendiği zaman model tahminlerinin bazı yüksek yakıt akışının olduğu anlarda oluşan az miktardaki sabit hatalar dışında oldukça başarılı olduğu görülmektedir. Modeller için yakıt akış hızında saatte 5000 pound hata payını 25 periyot yani yaklaşık 5 saniye aşarsa hata vardır şeklinde bir kural koyulursa yakıt sızıntısı hatasında tüm uçuşlar

için hata oluştuktan tam 5 saniye sonra hatanın tespit edildiği görülmüştür. Aynı şekilde sıfıra düşme hatası için ilk uçuş için 5 saniyede hata tespit edilmiş, ikinci uçuşun hata oluşma noktasından sonra yakıt akışı sıfıra yakın seyretmesinden ötürü hata tespit edilememiştir, son uçuşta yine hata oluştuktan 9 saniye sonra hata tespit edilebilmiştir.

6.5.3. Enlem-boylam değişim hızı hata tespiti

Küresel konumlama sensöründe gürültü durumu, sağlıklı şekilde üretilmiş olan üç test uçuş verisine eklenmiştir. Enlem ve Boylam değişim hızlarına, eğitim veri setindeki minimum ve maksimum değerler arasında rastgele eklenen gürültü ile bu sensörün hatalı veri üretmesi sağlanmıştır. Hata tüm uçuşların yarısında gerçekleşmiş sırasıyla 1100'üncü, 900'üncü ve 550'nci veri noktasından sonra eklenmişlerdir. Şekil 6.21'de üçüncü test uçuşu için boylam değişim hızında gürültülü veri hatasının oluşumu örnek olarak gösterilmiştir.



Şekil 6.20. Test uçuş-3 için gürültülü veri hatası oluşumu

Küresel konumlama sensöründe gerçekleşen gürültülü veri hatasının etkisi üçüncü test uçuşu için Şekil 6.21'de verilmiştir. Bu test uçuşu ve diğer iki test uçuşunun enlem ve boylam değişim hızı değerleri, diğer sensör verileri kullanılarak torbalama ağaçları modeliyle tahmin edilmiş ortaya Çizelge 6.24 ve 6.25'teki tablolar çıkmıştır.


Çizelge 6.24. Bağımsız uçuş test verileriyle yapılan enlem değişim hızı tahminleri

Uçuş	Gürültülü Veri Oluşan Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	$3,84 \times 10^{-6}$	$7,16 \times 10^{-7}$
Test Uçuş-2	$2,13 \times 10^{-6}$	$3,81 \times 10^{-7}$
Test Uçuş-3	$3,22 \times 10^{-6}$	$2,39 \times 10^{-7}$


Çizelge 6.25. Bağımsız uçuş test verileriyle yapılan boylam değişim hızı tahminleri

Uçuş	Gürültülü Veri Oluşan Uçuşun OKH değeri	Model Tahmini ile Oluşan Verinin OKH değeri
Test Uçuş-1	$3,93 \times 10^{-6}$	$6,01 \times 10^{-8}$
Test Uçuş-2	$5,2 \times 10^{-6}$	$1,94 \times 10^{-7}$
Test Uçuş-3	$6,57 \times 10^{-6}$	$3,45 \times 10^{-7}$


Geliştirilen modeller hem enlem değişim hızı hem de boylam değişim hızı için hatanın azaltılmasını sağlamıştır. Şekil 6.22, 6.23 ve 6.24'te boylam değişim hızını tahmin grafikleri test uçuşları için örnek olması için verilmiştir.



Şekil 6.21. Test uçuş-1'de boylam değişim hızı ve model tahminleri



Şekil 6.22. Test uçuş-2'de boylam değişim hızı ve model tahminleri




Şekil 6.23. Test uçuş-2'de boylam değişim hızı ve model tahminleri

Üç uçuş verisinin ikisi için boylam değişim hızları oldukça tutarlı görülürken, üçüncü test uçuşunda verilerdeki hatalar diğer iki uçuşa kıyasla daha fazla çıkmıştır. Bunun nedeni incelendiğinde ise test uçuş-3'ün gerçekleştiği koordinatların eğitim veri setinde bulunmamasından kaynaklandığı ortaya çıkmıştır.

6.6. Çoklu Sensör Hatası Durumunda Model Performansı


Çalışmanın son deneysel kısmı olarak önce yakıt akış hızı sensörünün ardından hücum açısı sensörünün arızalandığı durum oluşturulmuş ve geliştirilen modellerin hatayı bertaraf etme performansı değerlendirilmiştir. Öncelikle geliştirilen hücum açısı modeli için yakıt akış hızının önemi Matlab’da bulunun “predictorImportance” özelliği ile kontrol edilmiş ve tahmin performansı için yakıt akış hızı verisinin önemli olduğu bulunmuştur. Bu duruma örnek olarak Şekil 6.25’te üçüncü test uçuşunda 700. veriden itibaren yakıt sensörü sıfıra düşme hatası oluşturulmuş ve bunun hücum açısı algılayıcı tahminine etkisi verilmiştir. Şekilde görüldüğü üzere 700. veriden sonrası için bias’lı bir hata bulunmaktadır. Bu yüzden yakıt akışı hızı sensöründeki hata hücum açısına da direkt etkilediği görülmüştür.




Şekil 6.24. Test uçuş-3’te boylam değişim hızı ve model tahminleri

Daha sonrasında ise yakıt akış hızı için geliştirilen modelin hücum açısı verisinden ne kadar etkilendiği yine Matlab’da bulunan “predictorImportance” özelliği ile kontrol edilmiştir. Hücum açısı verisinin yakıt akış hızı tahminine etkisinin olmadığı görülmüştür. Bu sebepten bozulan bir hücum açısı verisinin yakıt akış hızı verisi tahminine etkisi olmadığı değerlendirilmiştir.


Üç test uçuşu verisi için de 700. veride yakıt akış hızı sıfıra düşme hatası oluşturulmuştur. Daha sonrasında yakıt akış hızı verisi ile yakıt akış hızı tahmini 5 saniye boyunca 5000'den fazla ise yakıt akış hız verisi değil de model tahmini girdi olarak kullanılmıştır. Bu sayede hücum açısı tahmini yapılırken hatalı yakıt akış hızı verisi değil yaklaşık şekilde tahmin edilen yakıt akış hızı kullanılmıştır. Şekil 6.26'da birinci test uçuşu verisinde 700. veride oluşan yakıt arızasının 725. veride yakıt akış hızı modeli ile düzeltilmesi sonucunda üretilen hücum açısı tahminleri verilmiştir. Şekil 6.27 ve 6.28'de sırasıyla ikinci ve üçüncü test uçuşu için aynı durum oluşturulmuş ve sonuçları verilmiştir. İlk uçuşun veri sayısı fazla olduğu için hata ve düzeltmenin görülmesi zor olsa da ikinci ve üçüncü uçuşlarda hata oluşumu ve düzeltme bariz şekilde görülmektedir.



Şekil 6.25. Test uçuş-1'de düzeltilen yakıt arızasının hücum açısı tahminine etkisi



Şekil 6.26. Test uçuş-3'te düzeltilen yakıt arızasının hücüm açısı tahminine etkisi



Şekil 6.27. Test uçuş-3'te düzeltilen yakıt arızasının hücüm açısı tahminine etkisi

Her üç uçuş verisi de incelendiğinde yakıt akış hızı sensörü arızalansa dahi yakıt akışı için oluşturulan model kullanılarak hücum açısı verisinin düzgün şekilde tahmin edilebildiği görülmüştür. Üç uçuş verisi de gösteriyor ki hücum açısında meydana gelebilecek son değerde takılı kalma veya sabit bias hatası gibi durumlar tahmin ve sensör verisi karşılaştırılarak bulunabilir. Bu sayede çoklu sensör hatalarının da tespit edilip düzeltilebildiği görülmüştür.

7. SONUÇ VE ÖNERİLER

Bu tez çalışmasında yıllar geçtikçe popülerliği artan havacılık alanında makine öğrenmesi metotları kullanılarak aviyonik sistem sensör verilerinde hataların tespiti üzerinde çalışılmıştır. Sensör verilerindeki hatalar hava araçlarının güvenli şekilde ulaşımı sağlaması ve görevleri başarılı şekilde icra etmeleri için yüksek risk oluşturmaktadır ve bu hatalar sebebiyle birçok kaza-kırım gerçekleşmiştir. Sensör verilerindeki hatalar sadece arızalardan dolayı gerçekleşmediği için çalışmada, sensör arızalarının yanı sıra sensörlere saldırı veya diğer sistemlerdeki problemler sebebiyle oluşan veri anormallikleri de incelenmiştir. Çalışmada, hücum açısı algılayıcısı için oluşan daha önce 737-8(MAX) uçaklarında meydana gelen sabit sapma arızası ve A320 tipi uçakta meydana gelen son değerde takılı kalma hataları incelenmiş, yakıt akış hızı sensörü verileri için Air Transat uçuş 236'da meydana gelen yakıt sızıntısı sebebiyle oluşan sabit fazla yakıt akış durumu ve sensör bağlantısı kopma durumunu ele alan sıfıra düşme hatası incelenmiş, küresel konumlama sistemi için saldırı sonucu oluşan gürültülü veri oluşma durumları incelenmiştir.

Bu tezde jet motorlu savaş uçağı F-16 üzerinde çalışılmıştır. Hata durumları incelenen sensörler, uçağın mimarisi düşünülerek bir sensörün bir veri ürettiği durumlar düşünülerek seçilmiştir. Çalışmada kullanılan diğer sensör verileri ise yine uçak mimarisi göz önünde bulundurularak uçak üzerinden elde edilebilecek verilerden oluşmaktadır. Uçuş verileri mühendislik uygulamalarında kullanılan uçuş simülatörü X-Plane kullanılarak toplanmıştır. Sorunsuz gerçekleştirilen uçuşlara sensör verilerindeki gerçekçi hata durumları eklenmiştir.

Makine öğrenmesi metotları birçok alanda olduğu gibi havacılıkta da son yıllarda arıza tespitinde kullanılmaya başlanmıştır. Bu çalışmada arıza ve anormalliklerin tespiti için uçak üzerindeki diğer sensörlerin veriyle tahmin yapan makine öğrenmesi teknikleri kullanılmıştır. Her bir sensör verisi için geliştirilen karar ağaçları, destek vektör regresyonu, torbalama ağaçları ve derin sinir ağları modelleri için parametreler eğitim veri setinde bekletme doğrulaması kullanılarak bulunmuştur. Her bir sensör için en başarılı modellere torbalama ağaçları kullanılarak ulaşıldığı görülmüştür. Daha sonra elde edilen en başarılı modeller hatalı sensör verisi içeren bağımsız test uçuşları ile denenmiş ve performansları ölçülmüştür.

Test uçuşlarında hücum açısı için 1 derecelik hata payını 25 periyot yani yaklaşık 5 saniye aşarsa hatalıdır denirse sapma hata durumunda üç uçuş için de hata durumunun tespit edildiği sadece bir kez yanlış alarm verildiği görülmüştür. Son değerle takılı kalma hatası için de aynı kural konulduğunda sırasıyla 5,5, 50 ve 9,5 saniye sonra hata tespiti yapıldığı görülmüştür. Test uçuşlarında hücum açısı verilerinin ortalama kare hata miktarı 0,5936'ya kadar düşen şekilde tahmin edilebildiği görülmüştür.

Test uçuşlarında yakıt akış hızı için saatte 5000 pound hata payını 25 periyot yani yaklaşık 5 saniye aşarsa hata vardır şeklinde bir kural koyulursa yakıt sızıntısı hatasında tüm uçuşlar için hata oluştuğundan tam 5 saniye sonra hatanın tespit edildiği, sıfıra düşme hatası için de üç test uçuşunun ikisinde hatanın tespit edilebildiği bir uçuş verisinde yakıt akışının belli aralıklarla düşük değerlerde seyrettiği için hatanın tespit edilemediği görülmüştür. Test uçuşlarında yakıt akış hızı verisi, $1,03 \times 10^6$ ortalama kare hata ile tahmin edilebildiği görülmüştür.

Küresel konumlama sistemi sensörü için diğer iki sensöre benzer bir kural konulmamıştır. Test uçuşları incelendiği zaman enlem değişim hızı için $7,16 \times 10^{-7}$ 'ya düşecek şekilde, boylam değişim hızı içinse $6,01 \times 10^{-8}$ OKH olacak şekilde tahminler yapıldığı görülmüştür.

Tezde son olarak çoklu sensör hataları üzerinde çalışılmıştır. Yakıt akış hızı ve hücum açısı sensörlerinin aynı uçuşta hatalı veri üretme durumu incelenmiştir. Yakıt akış hızında oluşacak sıfıra düşme hatasında bile hücum açısı sensör verisinin üç test uçuşu için de başarılı şekilde tahmin edildiği görülmüştür.

Bu tez çalışmasıyla birlikte makine öğrenmesi uygulamaları kullanılarak uçuşların güvenliğini ve görev başarımını etkilen sensör hatalarının tespit edilebildiği ve düzeltilebileceği görülmüştür. Tekli sensör hatasının üç sensör için ve çoklu sensör hatalarının iki sensör verisi için başarılı şekilde tespit edilebildiği görülmüştür. Bu çalışma genişletilerek hava araçlarına çıkabilen modeller edilebilir.

KAYNAKLAR

1. İnternet: Angle of Attack Vane Failure Modes. URL: <https://www.satcom.guru/2018/12/angle-of-attack-failure-modes.html>, Son Erişim Tarihi: 14.12.2022.
2. The Federal Democratic Republic of Ethiopia Ministry of Transport. (2020). Aircraft Accident Investigation Bureau Interim Investigation Report on Accident to the B737-8 (MAX) Registered ET-AVJ operated by Ethiopian Airlines Report No. AI-01/19. *AIB Report*. Addis Ababa, 8-9.
3. German Federal Bureau of Aircraft Accident Investigation. (2015). Interim Report; BFU 6X014-14. *BFU Report*. Braunschweig, 10-11.
4. Bureau d'Enquêtes et d'Analyses pour la sécurité de l'aviation civile. (2010). Report Accident on 27 November 2008 off the coast of Canet-Plage (66) to the Airbus A320-232 registered D-AXLA operated by XL Airways Germany. *BEA Report*. Paris, 11-12.
5. Government of Portugal Ministério Das Obras Públicas, Transportes E Comunicações Aviation Accidents Prevention and Investigation Department. (2001). Accident Investigation Final Report All Engines-out Landing Due to Fuel Exhaustion Air Transat Airbus A330-243 marks C-GITS. *GPIAA Report*. Lizbon, 1-2.
6. Agenzia Nazionale Per La Sicurezza Del Volo. (2008). Final Report Accident Involving Atr 72 Aircraft Registration Marks Ts-Lbb. *ANSV Report*. Roma, 14-16.
7. İnternet: Flight Foundation. URL: <https://aviation-safety.net/database/record.php?id=19961002-0>, Son Erişim Tarihi: 23.09.2021.
8. NASA Aviation Safety Reporting System. (2019). Controlled Flight Toward Terrain (CFTT). *NASA ASRS*. California, 473.
9. İnternet: Top 10 GPS Spoofing Events in History. URL: <https://threat.technology/top-10-gps-spoofing-events-in-history/>, Son Erişim Tarihi: 16.12.2022
10. İnternet: Health and Usage Monitoring System (HUMS). URL: <https://www.skybrary.aero/articles/health-and-usage-monitoring-system-hums>, Son Erişim Tarihi: 16.12.2022
11. McCool, K. M., Haas, D. J. Schaefer Jr, C.G. (1996). *A neural network based approach to helicopter low airspeed and sideslip angle estimation*. Flight Simulation Technologies Conference, San Diego, 91-101.
12. Srivastava, A. N. (2012). Greener aviation with virtual sensors: a case study. *Data Mining and Knowledge Discovery*, 24(2), 443-471.
13. Chati, Y. S., ve Balakrishnan, H. (2017). *A Gaussian process regression approach to model aircraft engine fuel flow rate*. ACM/IEEE 8th International Conference on Cyber-Physical Systems, Pittsburgh, 131-140.

14. Oza, N. C., Das, K. (2012). Reducing the environmental impact of aviation: a data mining approach to instantaneous estimation of fuel consumption. *NARI Report*. California, 1-6.
15. Qiancheng, W., Shunong, Z., Rui, K. (2011). *Research of small samples avionics prognostics based on Support Vector Machine*. 2011 Prognostics and System Health Management Conference, Montreal, 1-5.
16. Baskaya, E., Bronz, M., Delahaye, D. (2017). *Fault detection & diagnosis for small UAVs via machine learning*. 2017 IEEE/AIAA 36th Digital Avionics Systems Conference (DASC), St. Petersburg, 1-6.
17. Yan, W., Zhou, J. H. (2018). *Early fault detection of aircraft components using flight sensor data*. 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA), Torino, 1337-1342.
18. Swischuk, R., Allaire, D. (2019). A machine learning approach to aircraft sensor error detection and correction. *Journal of Computing and Information Science in Engineering*, 19(4). 1-14.
19. Mersha, B. W., Jansen, D. N., Ma, H. (2021). Angle of attack prediction using recurrent neural networks in flight conditions with faulty sensors in the case of F-16 fighter jet. *Complex & Intelligent Systems*, 1-13.
20. Shafiee, E., Mosavi, M. R., Moazedi, M. (2018). Detection of spoofing attack using machine learning based on multi-layer neural network in single-frequency GPS receivers. *The Journal of Navigation*, 71(1), 169-188.
21. Kılıç, U., Ünal, G. (2021). Aircraft air data system fault detection and reconstruction scheme design. *Aircraft Engineering and Aerospace Technology*, 93(6), 1104-1114.
22. Bronz, M., Baskaya, E., Delahaye, D., Puechmore, S. (2020). *Real-time fault detection on small fixed-wing UAVs using machine learning*. 2020 AIAA/IEEE 39th Digital Avionics Systems Conference (DASC), San Antonio, 1-10.
23. İnternet : Introduction to Avionics. URL: https://www.acsce.edu.in/acsce/wp-content/uploads/2020/03/Avionics-Vol_1.pdf, Son Erişim Tarihi: 16.12.2022.
24. Lockheed Martin Corporation. (1998). *F-16 A/B Mid-Life Update Production Tape MI The Pilot's Guide to new capabilities&cockpit enhancements*. Maryland: Lockheed Martin, 217.
25. İnternet : Design of nonlinear control of gas turbine engine based on constant eigenvectors. URL: <https://www.mdpi.com/2075-1702/9/3/49/htm>, Son Erişim Tarihi: 16.12.2022.
26. İnternet : The Air Data Computer (ADC). URL: https://www.youtube.com/watch?v=_cMrmuMOo-k, Son Erişim Tarihi: 16.12.2022.
27. Collinson, R. P. (2013). *Introduction to avionics systems*. Berlin: Springer Science & Business Media, 1-50.

28. İnternet : Inertial Navigation System (INS). URL: <https://support.sbg-systems.com/sc/kb/latest/integrated-motion-navigation-sensors/inertial-navigation-system-ins>, Son Erişim Tarihi: 16.12.2022.
29. Tagebrand, E., Gustafsson Ek, E. (2021). *Dataset Generation in a Simulated Environment Using Real Flight Data for Reliable Runway Detection Capabilities*. Master Thesis, Mälardalen University School of Innovation Design and Engineering, Västerås.
30. Li, G., Rai, A., Lee, H., Chattopadhyay, A. (2018). *Operational anomaly detection in flight data using a multivariate gaussian mixture model*. PHM Society Conference, Philadelphia, 1-8.
31. İnternet : X-Plane 10 Benchmarked. URL: <https://www.notebookcheck.net/X-Plane-10-Benchmarked.111450.0.html>, Son Erişim Tarihi: 16.12.2022.
32. İnternet : FAA-Certified X-Plane. URL: <https://www.x-plane.com/pro/certified/>, Son Erişim Tarihi: 16.12.2022.
33. İnternet : Flight Testing in a Simulation Based Environment. URL: <https://core.ac.uk/download/pdf/19143414.pdf>, Son Erişim Tarihi: 16.02.2023.
34. Nanduri, A., Sherry, L. (2016). *Generating Flight Operations Quality Assurance (FOQA) Data from the X-Plane Simulation*. 2016 Integrated Communications Navigation and Surveillance (ICNS), Herndon, 5C1-5C9.
35. Boeing. (2021). Statistical Summary Of Commercial Jet Airplane Accidents Worldwide Operations 1959 – 2020. *Boeing Report*. Arlington, 14.
36. İnternet : What Is a Decision Tree and How Is It Used?. URL: <https://careerfoundry.com/en/blog/data-analytics/what-is-a-decision-tree/>, Son Erişim Tarihi: 16.12.2022.
37. İnternet : Decision Trees in Machine Learning, with Examples (Python). URL: <https://www.jcchouinard.com/decision-trees-in-machine-learning/>, Son Erişim Tarihi: 16.12.2022.
38. İnternet : Support Vector Machine - Regression (SVR). URL: http://www.saedsayad.com/support_vector_machine_reg.htm, Son Erişim Tarihi: 16.12.2022.
39. Alpaydın, E. (2020). *Introduction to machine learning*. (3. Baskı). Massachusetts: MIT press. 351-358.
40. İnternet : Bagging Decision Trees — Clearly Explained. URL: <https://towardsdatascience.com/bagging-decision-trees-clearly-explained-57d4d19ed2d3>, Son Erişim Tarihi: 16.12.2022.
41. İnternet : Ensemble Algorithms. URL: <https://www.mathworks.com/help/stats/ensemble-algorithms.html>, Son Erişim Tarihi: 16.12.2022.

42. İnternet : Ensemble Models: Bagging vs. Boosting URL: <https://medium.com/analytics-vidhya/ensemble-models-baggings-vs-boosting-8affa6d18098>, Son Erişim Tarihi: 16.12.2022.
43. İnternet : What is a Neural Network? URL: <https://www.tibco.com/reference-center/what-is-a-neural-network>, Son Erişim Tarihi: 16.12.2022.
44. İnternet : traingdx Gradient descent with momentum and adaptive learning rate backpropagation URL: <https://www.mathworks.com/help/deeplearning/ref/traingdx.html>, Son Erişim Tarihi: 16.12.2022.



Gazili olmak ayrıcalıktır