



**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI**

YÜKSEK LİSANS TEZİ

**SİNYAL İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİNİ
KULLANARAK İNSANSIZ HAVA ARAÇLARINDA ERKEN
ARIZA TESPİTİ**

**Yazar
Alican YILMAZ**

**Danışman
Doç. Dr. Erkan Caner ÖZKAT**

**RİZE
2026**



**T.C.
RECEP TAYYİP ERDOĞAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI
MAKİNE MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

**SİNYAL İŞLEME VE DERİN ÖĞRENME YÖNTEMLERİNİ
KULLANARAK İNSANSIZ HAVA ARAÇLARINDA ERKEN
ARIZA TESPİTİ**

Yüksek Lisans

Alican YILMAZ

**Danışman
Doç. Dr. Erkan Caner ÖZKAT**

**RİZE
2026**

KABUL VE ONAY

Recep Tayyip Erdoğan Üniversitesi, Lisansüstü Eğitim Enstitüsü, Makine Mühendisliği Anabilim Dalı, Makine Mühendisliği Tezli Yüksek Lisans Programında, Doç. Dr. Erkan Caner ÖZKAT danışmanlığında, Alican YILMAZ tarafından hazırlanan **Sinyal İşleme ve Derin Öğrenme Yöntemlerini Kullanarak İnsansız Hava Araçlarında Erken Arıza Tespiti** adlı bu tez çalışması, 30/06/2026 tarihinde yapılan savunma sınavı sonucunda oy birliğiyle başarılı bulunarak jürimiz tarafından **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Jüri Üyeleri	Ünvanı, Adı SOYADI	Sonuç
Başkan	: Prof. Dr. Mete AVCI	☒ Kabul ☐ Ret
Üye	: Prof. Dr. Temel KOTİL	☒ Kabul ☐ Ret
Üye	: Prof. Dr. Erdal ÇELİK	☒ Kabul ☐ Ret
Üye	: Prof. Dr. Faruk ÖZEL	☒ Kabul ☐ Ret
Üye	: Doç. Dr. Erkan Caner ÖZKAT	☒ Kabul ☐ Ret

ETİK BEYAN

Makine Mühendisliği Anabilim Dalı Makine Mühendisliği Tezli Yüksek Lisans Programından mezun olmak üzere teslim ettiğim **Sinyal İşleme ve Derin Öğrenme Yöntemlerini Kullanarak İnsansız Hava Araçlarında Erken Arıza Tespiti** adlı tezim, bilim ve araştırma etiği prensiplerine riayet edilerek tarafımdan yazılmıştır.

Tez çalışmamda, başka kaynaklardan aktarılan bütün bilgi ve alıntılar, Enstitünüz Tez Yazım Kılavuzuna uygun olarak açıkça gösterilmiştir. Kaynağı gösterilenler dışında kalan bütün bilgiler uygun araştırma yöntemi kullanılarak tarafımdan edinilmiş ve esere bu şekilde yansıtılmıştır. Şahsıma ait olmayan hiçbir bilgi, kasıt veya kusurlar, şahsıma aitmiş gibi gösterilmemiştir. İnternet kaynakları dâhil, sahibine/kaynağına atıf yapılmaksızın hiçbir bilgi kullanılmamıştır. Aksinin ortaya çıkması halinde doğacak bütün hukuki, idari, akademik ve etik sorumluluk tarafıma ait olacaktır. Eserin tesliminden sonra herhangi bir zamanda, bilim etiğine aykırılık tespit edilmesi ve / veya eserimle ilgili intihal veya intihal şeklinde anlaşılabilecek bir durumun ortaya çıkması halinde; Üniversiteniz ve eğitim kadronuzun hiçbir şekilde sorumlu tutulmayacağını hür irademle kabul, beyan ve taahhüt ederim.

30/06/2026

Alican YILMAZ

ÖN SÖZ

Bu tez çalışması, insansız hava araçlarında (İHA) pervane kaynaklı yapısal arızaların erken tespitine yönelik veri temelli yöntemlerin geliştirilmesi amacıyla hazırlanmıştır. İHA'ların savunma, tarım, lojistik ve altyapı denetimi gibi kritik alanlarda yaygınlaşması, uçuş güvenliğini artıracak ve bakım süreçlerini iyileştirecek akıllı karar destek sistemlerine olan ihtiyacı artırmaktadır. Bu kapsamda, İHA gövdesine entegre edilen ivmeölçer sensöründen elde edilen titreşim verileri kullanılarak makine öğrenmesi tabanlı arıza sınıflandırması ve denetimsiz derin öğrenme tabanlı anomali tespiti yaklaşımları geliştirilmiştir. Geliştirilen yöntemlerin, İHA itki sistemleri için veri temelli akıllı bakım uygulamalarına katkı sunması ve güvenilir arıza yönetim yaklaşımlarına temel oluşturması hedeflenmektedir.

Tez çalışması kapsamında Signal Intelligence: Vibration-Driven Deep Learning for Anomaly Detection of Rotary-Wing UAVs ve A Low-Cost Wireless Accelerometer Approach to UAV Propeller Fault Detection başlıklı makaleler ile Deep Learning-Based Propeller Sound Classification Using GoogLeNet ve Scalogram-Driven Deep Learning for Reliable Fault Diagnosis in Rotating Machinery başlıklı bildiriler hazırlanmıştır. Ayrıca, araştırma sürecinde TUSAŞ (Türk Havacılık ve Uzay Sanayii A.Ş.) Hangar Kampüs Programı kapsamında sağlanan mentorluk ve teknik yönlendirmelerinden ötürü TUSAŞ'a teşekkür ederim.

“Bu çalışma Recep Tayyip Erdoğan Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü birimince desteklenmiştir. Proje Numarası: BAP- FBA-2025-1947” (“This work was supported by the Research Fund of Recep Tayyip Erdogan University. Project Number: BAP- FBA-2025-1947”)

Tez çalışmam boyunca bilgi, deneyim ve akademik rehberliğiyle bana yol gösteren, danışmanım Doç. Dr. Erkan Caner ÖZKAT'a; tez jürimde yer alarak değerli görüş ve önerileriyle çalışmama katkı sağlayan Prof. Dr. Temel KOTİL, Prof. Dr. Erdal ÇELİK, Prof. Dr. Mete AVCI ve Prof. Dr. Faruk ÖZEL'e; son olarak ise hayatımın her aşamasında sevgi, sabır, anlayış ve koşulsuz destekleriyle daima yanımda olan kıymetli aileme en derin şükranlarımı sunarım.

Alican YILMAZ

RİZE/2026

İÇİNDEKİLER

KABUL VE ONAY	I
ETİK BEYAN	II
ÖN SÖZ	III
İÇİNDEKİLER	IV
ÖZET.....	VII
ABSTRACT.....	VIII
KISALTMALAR	IX
TABLolar LİSTESİ	XII
ŞEKİLLER LİSTESİ	XIII
GİRİŞ	1
1. GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI.....	4
2. İNSANSIZ HAVA ARAÇLARI.....	13
2.1. İnsansız Hava Aracı Tanımı.....	13
2.2. İnsansız Hava Araçları Sınıflandırılması.....	21
2.2.1. Sabit Kanatlı İnsansız Hava Araçları	22
2.2.2. Döner Kanatlı İnsansız Hava Araçları	24
2.2.3. Hibrit İnsansız Hava Araçları	28
3. İNSANSIZ HAVA ARAÇLARINDA ARIZA TESPİTİ	32
3.1. Arıza Tespiti için Kullanılan Yöntemler	33
3.2. Kestirimci Bakım	35
3.2.1. İnsansız Hava Araçlarında Kullanılan Veriler	37
3.2.2. Veriye Dayalı Kalan Faydalı Ömür Tahmini	40
3.2.3. Veriye Dayalı Anomali Tespiti.....	42
3.3. Arıza Tespitinde Yapay Zeka Kullanımı.....	44
3.3.1. Sinyal İşleme	50
3.3.2. Derin Öğrenme	56
4. MATERYAL.....	59
4.1. İnsansız Hava Aracı Bileşenleri	59
4.1.1. Gövde.....	60
4.1.2. Motor	62
4.1.3. Elektronik Hız Kontrol Ünitesi.....	65

4.1.4. Batarya.....	67
4.1.5. Pervane	68
4.1.6. Uçuş Kontrol Kartı	70
4.1.7. Telemetri	72
4.1.8. GPS.....	74
4.1.9. Kumanda.....	76
4.1.10. Sensörler	78
4.2. Çalışmada Kullanılan Deney Düzeneği	80
4.3. Gerçek Zamanlı Veri Toplama.....	85
5. ÇALIŞMADA KULLANILAN YÖNTEM	91
5.1. Birinci Yaklaşım: Klasik Makine Öğrenmesi ile Pervane Arıza Sınıflandırması	91
5.1.1. Veri Ön İşleme ve Öznitelik Çıkarımı	92
5.1.2. Kullanılan Makine Öğrenmesi Yöntemleri.....	92
5.1.2.1. Rastgele Orman (Random Forest, RF).....	93
5.1.2.2. Destek Vektör Makinesi (Support Vector Machine, SVM).....	93
5.1.2.3. k-En Yakın Komşu (k-Nearest Neighbors, KNN)	94
5.1.2.4. Karar Ağacı (Decision Tree, DT).....	94
5.2. İkinci Yaklaşım: Denetimsiz Derin Öğrenme ile Anomali Tespiti	95
5.2.1. Sürekli Dalgacık Dönüşümü Tabanlı Zaman–Frekans Temsili	95
5.2.2. Şiddete Göre Sıralanmış Veri Zenginleştirme	96
5.2.3. CNN–BiGRU–SSM–AE Mimarisi.....	98
5.2.3.1. Evrişimli Kodlayıcı (CNN).....	99
5.2.3.2. Gaz Farkındalıklı Koşullandırma.....	100
5.2.3.3. BiGRU ile Zamansal Modelleme.....	100
5.2.3.4. SSM Durum-Uzayı Bloğu.....	100
5.2.3.5. Kod Çözücü ve Kayıp Fonksiyonu	101
5.2.4. Anomali Skorlama ve Eşikleme	101
5.3. Değerlendirme Metrikleri.....	101
6. BULGULAR VE TARTIŞMA	103
6.1. Klasik Makine Öğrenmesi Tabanlı Sınıflandırma Bulguları.....	103
6.1.1. Titreşim Karakteristikleri.....	103
6.1.2. Çoklu Sınıf Sınıflandırma Sonuçları	105

6.1.3. İkili Sınıflandırma Sonuçları	107
6.1.4. Çapraz Doğrulama Kararlılığı	108
6.2. Denetimsiz Derin Öğrenme Tabanlı Anomali Tespit Bulguları	110
6.2.1. Sağlıklı Temel Davranışı	110
6.2.2. Şiddetli Yapısal Arıza	111
6.2.3. Temel Frekans ve RMS Eğilimleri	111
6.2.4. Şiddete Göre Sıralanmış Zenginleştirilmiş Veri	113
6.2.5. Anomali Tespit Performansı Karşılaştırması	115
6.2.6. Ablasyon Çalışması	116
6.3. Bulguların Genel Değerlendirilmesi	117
7. SONUÇ VE ÖNERİLER	118
7.1. Genel Sonuçlar	118
7.2. Öneriler ve Gelecek Çalışmalar	119
KAYNAKÇA	123

ÖZET

Recep Tayyip Erdoğan Üniversitesi Lisansüstü Eğitim Enstitüsü

Makine Mühendisliği Anabilim Dalı

Hazırlayan: Alican YILMAZ

Yüksek Lisans Tezi

Danışman: Doç. Dr. Erkan Caner ÖZKAT

Yıl: 2026, Sayfa Sayısı: 148

Sinyal İşleme ve Derin Öğrenme Yöntemlerini Kullanarak İnsansız Hava Araçlarında Erken Arıza Tespiti

İnsansız hava araçlarının (İHA) savunma, tarım, lojistik ve altyapı denetimi gibi kritik alanlarda kullanımının artması, uçuş güvenliğini artıracak ve bakım süreçlerini optimize edecek akıllı sistemlere olan ihtiyacı da beraberinde getirmiştir. Özellikle pervane kaynaklı yapısal arızalar, uçuş kararlılığı ve görev başarısını doğrudan etkileyen kritik arıza türleri arasında yer almaktadır. Literatürdeki çalışmaların yaklaşık %80' i yalnızca denetimli arıza sınıflandırmasına odaklanırken, titreşim verileri çoğunlukla kablolu sistemlerle toplanmaktadır. Bu tezde, İHA pervane arızalarının erken tespitine yönelik, gerçek uçuş deneylerinden elde edilen titreşim verileri kullanılarak bütünsel bir yapay zekâ çerçevesi geliştirilmiştir. Çalışma kapsamında titreşim verileri, ADXL345 ivmeölçer sensörü ve ESP32 Wi-Fi modülü kullanılarak kablosuz olarak gerçek zamanlı biçimde toplanmış ve çevrimdışı analiz edilmiştir. Önerilen yaklaşım, bilinen pervane arızalarının denetimli olarak sınıflandırılmasını ve daha önce görülmemiş anomalilerin denetimsiz olarak tespit edilmesini birlikte ele alması bakımından literatürdeki mevcut çalışmalardan ayrılmaktadır.

Çalışmanın ilk aşamasında, kontrollü olarak oluşturulan farklı pervane arıza senaryolarından elde edilen üç eksenli titreşim verileri kullanılmıştır. Titreşim sinyallerinden çıkarılan 27 istatistiksel öznitelik ile Rastgele Orman, Destek Vektör Makinesi, k-En Yakın Komşu ve Karar Ağacı algoritmaları karşılaştırılmıştır. Yapılan analizler sonucunda Rastgele Orman algoritması, ikili (sağlıklı/arızalı) sınıflandırmada %94,44, yedi sınıflı arıza sınıflandırmasında ise %83,33 test doğruluğu ile en başarılı yöntem olarak belirlenmiştir.

Çalışmanın ikinci aşamasında, etiketli verilere bağımlılığı azaltmak ve erken evre arızaları tespit etmek amacıyla denetimsiz derin öğrenme yöntemi kullanılmıştır. Üç eksenli titreşim sinyalleri Sürekli Dalgacık Dönüşümü ile zaman-frekans görüntülerine dönüştürülmüş, arıza şiddetine göre sıralanmış özgün bir veri zenginleştirme stratejisi geliştirilmiş ve CNN-BiGRU-SSM-AE tabanlı hibrit otoenkoder mimarisi önerilmiştir. Önerilen model, 0,9284 AUROC değeri ile karşılaştırılan temel anomali tespit yöntemlerinden daha yüksek performans göstermiş ve etiketli veriye ihtiyaç duymadan erken evre anomalilerin güvenilir biçimde tespit edilebildiğini ortaya koymuştur.

Elde edilen bulgular, geliştirilen yaklaşımın İHA pervane arızalarının erken tespitinde etkin biçimde uygulanabildiğini göstermektedir. Önerilen bütünsel metodoloji, klasik makine öğrenmesi ile denetimsiz derin öğrenme yaklaşımlarını bir araya getirerek hem bilinen arızaların sınıflandırılmasına hem de erken evre anomalilerin belirlenmesine olanak sağlamaktadır. Bu yönüyle çalışma, İHA'larda veri temelli sağlık izleme, kestirimci bakım uygulamaları ve gelecekte geliştirilecek gerçek zamanlı yapay zekâ tabanlı karar destek sistemleri için önemli bir altyapı sunmaktadır.

Anahtar Kelimeler: İnsansız Hava Aracı, Arıza Tespiti, Titreşim Analizi, Makine Öğrenmesi, Derin Öğrenme, Anomali Tespiti, Kestirimci Bakım

ABSTRACT

Recep Tayyip Erdogan University Institute of Graduate Studies

Department of Mechanical Engineering

Author: Alican YILMAZ

Master's Thesis

Supervisor: Assoc.Prof. Dr. Erkan Caner ÖZKAT

Year: 2026, Pages: 148

Early Fault Detection in Unmanned Aerial Vehicles Using Signal Processing and Deep Learning Methods

The increasing use of Unmanned Aerial Vehicles (UAVs) in critical fields such as defense, agriculture, logistics, and infrastructure inspection has created a growing demand for intelligent systems capable of improving flight safety and optimizing maintenance processes. Among various failure modes, propeller-related structural faults are considered one of the most critical factors affecting flight stability and mission success. Approximately 80% of the studies reported in the literature focus solely on supervised fault classification, while vibration data are predominantly collected using wired acquisition systems. In this thesis, an integrated artificial intelligence framework was developed for the early detection of UAV propeller faults using vibration data collected from real flight experiments. The vibration data were acquired wirelessly in real time using an ADXL345 accelerometer and an ESP32 Wi-Fi module, and subsequently analyzed offline. The proposed approach distinguishes itself from existing studies by integrating the supervised classification of known propeller faults with the unsupervised detection of previously unseen anomalies within a unified framework.

In the first stage of the study, three-axis vibration data obtained from controlled propeller fault scenarios were utilized. Twenty-seven statistical features extracted from the vibration signals were used to compare the performance of the Random Forest, Support Vector Machine, k-Nearest Neighbors, and Decision Tree algorithms. The Random Forest algorithm achieved the best performance, yielding test accuracies of 94.44% for binary (healthy/faulty) classification and 83.33% for seven-class fault classification.

In the second stage, an unsupervised deep learning approach was employed to reduce dependence on labeled data and enable the detection of early-stage faults. Three-axis vibration signals were transformed into time-frequency representations using the Continuous Wavelet Transform (CWT). A novel fault severity-based data augmentation strategy was developed, and a hybrid CNN–BiGRU–SSM–AE autoencoder architecture was proposed. The proposed model outperformed the baseline anomaly detection methods by achieving an AUROC score of 0.9284, demonstrating that early-stage anomalies can be reliably detected without requiring labeled data.

The experimental results demonstrate that the proposed approach can be effectively applied to the early detection of UAV propeller faults. The proposed integrated methodology combines classical machine learning and unsupervised deep learning within a unified framework, enabling both the classification of known faults and the detection of early-stage anomalies. Consequently, this study provides an important foundation for data-driven health monitoring, predictive maintenance applications, and the future development of real-time artificial intelligence-based decision support systems for UAVs.

Keywords: Unmanned Aerial Vehicle, Fault Detection, Vibration Analysis, Machine Learning, Deep Learning, Anomaly Detection, Predictive Maintenance

KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ADXL345	: Analog Devices Üç Eksenli MEMS Dijital İvmeölçer
AE	: Otoenkoder (Autoencoder)
AI	: Yapay Zekâ (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
ARIMA	: Autoregressive Integrated Moving Average
AUROC	: ROC Eğrisi Altındaki Alan (Area Under the ROC Curve)
BiGRU	: Çift Yönlü Geçitli Tekrarlayan Birim (Bidirectional GRU)
BVLOS	: Görüş Hattı Dışı Uçuş (Beyond Visual Line of Sight)
CBS	: Coğrafi Bilgi Sistemleri
CCW	: Saat Yönünün Tersine (Counterclockwise)
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
CoG	: Ağırlık Merkezi (Center of Gravity)
CW	: Saat Yönünde (Clockwise)
CWT	: Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform)
DBN	: Derin İnanç Ağları (Deep Belief Network)
DGPS	: Diferansiyel Küresel Konumlandırma Sistemi
DL	: Derin Öğrenme (Deep Learning)
DRL	: Derin Takviyeli Öğrenme (Deep Reinforcement Learning)
DRSCN	: Deep Residual Stochastic Configuration Network
DT	: Karar Ağaçları (Decision Trees)
EASA	: Avrupa Birliği Havacılık Emniyeti Ajansı (European Union Aviation Safety Agency)
ESC	: Elektronik Hız Kontrol Ünitesi
ESP32	: ESP32 Mikrodenetleyici
FAA	: Federal Havacılık İdaresi (Federal Aviation Administration)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FT	: Fourier Dönüşümü (Fourier Transform)
GAN	: Çekişmeli Üretici Ağ (Generative Adversarial Network)
GBT	: Genetic-Based Theory
GPS	: Küresel Konumlandırma Sistemi (Global Positioning System)

GPU	: Grafik İşlemci Birimi (Graphics Processing Unit)
GRU	: Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
IAI	: Israel Aerospace Industries
ICA	: Bağımsız Bileşen Analizi (Independent Component Analysis)
İHA	: İnsansız Hava Aracı
IMU	: Ataletsel Ölçüm Birimi (Inertial Measurement Unit)
INS	: Ataletsel Navigasyon Sistemi (Inertial Navigation System)
IQR	: Çeyrekler Arası Açıklık (Interquartile Range)
KFÖ	: Kalan Faydalı Ömür
KLD	: Kullback-Leibler İraksaması (Kullback-Leibler Divergence)
kNN	: k-En Yakın Komşu (k-Nearest Neighbors)
Li-Ion	: Lityum İyon
Li-Po	: Lityum Polimer
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ML	: Makine Öğrenmesi (Machine Learning)
OC-SVM	: Tek Sınıflı Destek Vektör Makinesi (One-Class SVM)
PCA	: Temel Bileşen Analizi (Principal Component Analysis)
PdM	: Kestirimci Bakım (Predictive Maintenance)
PDP	: Paralel Dağıtık İşleme
PID	: Oransal-İntegral-Türevsel Denetleyici (Proportional-Integral-Derivative)
PSD	: Güç Spektral Yoğunluğu (Power Spectral Density)
RF	: Rastgele Orman (Random Forest)
RLS	: Recursive Least Squares
RMS	: Karekök Ortalama (Root Mean Square)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
RTK	: Gerçek Zamanlı Kinematik (Real-Time Kinematic)
RUL	: Kalan Faydalı Ömür (Remaining Useful Life)
S3VM	: Yarı Gözetimli Destek Vektör Makinesi (Semi-Supervised SVM)
SCN	: Stokastik Konfigürasyon Ağı (Stochastic Configuration Network)
SİHA	: Silahlı İnsansız Hava Aracı
SMOTE	: Sentetik Azınlık Aşırı Örnekleme Tekniği (Synthetic Minority Oversampling Technique)

SOM	: Kendi Kendini Örgütleyen Harita (Self-Organizing Map)
SSM	: Durum Uzayı Modeli (State Space Model)
STFT	: Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform)
SVM	: Destek Vektör Makinesi (Support Vector Machine)
TUSAŞ	: Türk Havacılık ve Uzay Sanayii A.Ş.
U.S.	: United States
UAV	: Unmanned Aerial Vehicle
VTOL	: Dikey Kalkış ve İniş (Vertical Takeoff and Landing)
WT	: Dalgacık Dönüşümü (Wavelet Transform)
WVD	: Wigner-Ville Dağılımı

TABLÖLAR LİSTESİ

Tablo 1. Kalan Faydalı Ömür Çalışmaları.....	7
Tablo 2. Anomali Tespiti Çalışmaları.....	9
Tablo 3. Yapay Zekanın Tarihsel Süreçleri.....	45
Tablo 4. Yedi Konfigürasyon için Y-Eksen İvme Verisi İstatistiksel Özeti (m/s ²) .	103
Tablo 5. Çoklu Sınıf Sınıflandırma Sonuçları (Yedi Sınıf, %30 Test Kümesi)	105
Tablo 6. Rastgele Orman Sınıflandırıcısının Yedi Sınıflı Bazında Başarımı.....	106
Tablo 7. İkili Sınıflandırma Sonuçları (Sağlıklı vs. Arızalı, %30 Test Kümesi)	108
Tablo 8. 5-Katlı Tabakalı Çapraz Doğrulama Sonuçları (Ortalama ± Standart Sapma)	108
Tablo 9. Anomali Tespit Performansının Niceliksel Karşılaştırması.....	115
Tablo 10. Güncel Döner Kanat İHA Anomali Tespit Yöntemleriyle Karşılaştırma	116
Tablo 11. Ablasyon Çalışması Sonuçları	117

ŞEKİLLER LİSTESİ

Şekil 1. Kettering Bug (National Museum)	14
Şekil 2. V-1 Uçan Bomba (U.S. Air Force photo)	15
Şekil 3. Ryan Firebee (San Diego Air and Space)	15
Şekil 4. Scout (IAI)	16
Şekil 5. RQ-1 Predator (Inteligence Resource Program).....	16
Şekil 6. a) Anka b) Aksungur	17
Şekil 7. a) Bayraktar Mini İHA b) Bayraktar TB2.....	18
Şekil 8. a) Bayraktar Kızılelma b) Anka III	18
Şekil 9. Sabit Kanatlı İnsansız Hava Aracı	22
Şekil 10. Döner Kanatlı İnsansız Hava Aracı	24
Şekil 11. a) Quadrotor, b) Hexacopter ve c) Octocopter.....	25
Şekil 12. Kamikaze İnsansız Hava Aracı (STM Savunma)	27
Şekil 13. Sürü İnsansız Hava Araçları (MSI Turkish Defence,2020)	27
Şekil 14. Hibrit İnsansız Hava Aracı	28
Şekil 15. Bayraktar Kalkan (BAYKAR).....	30
Şekil 16. Bakım Yöntemlerinin Maliyetleri.....	37
Şekil 17. Kestirimci Bakımda Kullanılan Veriler	38
Şekil 18. Kalan Faydalı Ömür Tahminin Avantajları.....	41
Şekil 19. Denetimli Öğrenme Yöntemleri	48
Şekil 20. Denetimsiz Öğrenme Yöntemleri	49
Şekil 21. İnsansız Hava Aracı Bileşenleri.....	59
Şekil 22. MARK4 V3 Pro 15 Inch 680 mm T8 Karbon Fiber Drone Gövdesi	61
Şekil 23. GEPRC EM4218 350KV Fırçasız Motor	63
Şekil 24. GEPRC 4IN1 ESC	65
Şekil 25. 6S 16000 mAh Li-Po Batarya	67
Şekil 26. HQProp 15 İnç Pervane	69
Şekil 27. SpeedyBee F405 Uçuş Kontrol Kartı	71
Şekil 28. SIYI Alıcı-Verici Telemetry.....	73
Şekil 29. Readytosky Ublox NEO M8N GPS	75
Şekil 30. SIYI MK15 Kumanda	77
Şekil 31. Çalışmada Kullanılan İHA	80

Şekil 32. Birinci Yaklaşımda Kullanılan Arıza Konfigürasyonu	83
Şekil 33. Pervane Üzerinde Uygulanan Kontrollü Yapısal Modifikasyonların Radyal Konumları.	84
Şekil 34. İkinci Yaklaşımda Kullanılan Arıza Konfigürasyonu (a) A Konumunda Uygulanan Bant Kaynaklı Kütle Dengesizliği; (b) B Konumunda Uygulanan Çizik Hatası; (c) C Konumunda Uygulanan Tam Kesimim ve (d) Sağlıklı Pervane Konfigürasyonu.....	84
Şekil 35. Veri Toplama Sisteminde Kullanılan Sensörler	85
Şekil 36. ESP32 Tabanlı Kablosuz Veri Toplama Mimarisi ve ADXL345 İvmeölçerin Yerleştirilmesi	86
Şekil 37. Sensör Setinin İHA Üzerine Yerleştirilmesi	87
Şekil 38. MATLAB Üzerinden Anlık Veri Takibi.....	87
Şekil 39. MATLAB Kodu	89
Şekil 40. Üç Fazlı Uçuş Protokolünün Zaman Çizelgesi (Havada Asılı Kalma, Manevra ve Sert Uçuş Fazları).....	91
Şekil 41. Şiddete Göre Sıralanmış Veri Zenginleştirme Algoritmasının Akış Şeması.	98
Şekil 42. CNN–BiGRU–SSM–AE Hibrit Otoenkoder Mimarisinin Blok Diyagramı.	99
Şekil 43. Yedi Pervane Konfigürasyonu İçin Temsili Üç Eksenli İvme Zaman Serileri.	104
Şekil 44. Pervane Konfigürasyonlarına Göre Eksen Bazında İvme Dağılımlarının Kutu Grafiği.	104
Şekil 45. Uçuş Fazlarına Göre RMS İvme Genliğinin Karşılaştırılması.	105
Şekil 46. Rastgele Orman Sınıflandırıcısının Yedi Sınıflı Karmaşıklık Matrisi.	107
Şekil 47. Rastgele Orman Modeline Göre En Ayırt Edici 15 Özniteliğin Önem Sıralaması.	107
Şekil 48. Dört Klasik Sınıflandırıcısının İkili ve Çoklu Sınıf Görevlerdeki Test Doğruluğu Karşılaştırması.	109
Şekil 49. 5-Katlı Tabakalı Çapraz Doğrulamada Sınıflandırıcı Doğruluklarının Ortalama ve Standart Sapması.	109
Şekil 50. Sağlıklı Pervanenin Kademeli Gaz Profili Altında Zaman ve Zaman–Frekans Gösterimi.....	110

Şekil 51. Tam Kesim (C Konumu) Arızasının Zaman ve Zaman–Frekans Gösterimi.	111
Şekil 52. Tüm Pervane Koşulları İçin Güç Spektral Yoğunluğu (PSD) Karşılaştırması.	112
Şekil 53. Gaz Konumuna Göre Temel Dönme Frekansının Değişimi.	113
Şekil 54. Gaz Konumuna Göre RMS İvme Genliğinin Değişimi.....	113
Şekil 55. Şiddete Göre Sıralanmış Zenginleştirme ile Elde Edilen Sürekli Üç Eksenli Titreşim Serisi.	114
Şekil 56. Zenginleştirilmiş Verinin Zaman–Frekans (Spektrogram) Gösterimi.	114
Şekil 57. Dört Anomali Tespit Yönteminin Başarım Metriklerine Göre Karşılaştırması.	116

GİRİŞ

Havacılık ve savunma sanayii, teknoloji ile entegre edilen akıllı sistemlerin giderek daha fazla önem kazandığı, yüksek mühendislik çözümlerine dayalı bir alan olarak ön plana çıkmaktadır. Özellikle İnsansız Hava Araçları (İHA), askeri ve sivil uygulamalar başta olmak üzere, geniş bir kullanım alanına sahip olup, havacılık sektöründeki en kritik teknolojilerden biri haline gelmiştir. Keşif, gözetleme, haritalama, lojistik, afet yönetimi ve güvenlik gibi çeşitli alanlarda aktif olarak kullanılan İHA'ların operasyonel başarısı, mekanik ve elektronik sistemlerinin güvenilirliği ile doğrudan ilişkilidir. Ancak, İHA'ların uzun süreli ve etkin bir şekilde görev yapabilmesi için düzenli bakım süreçlerinin titizlikle yürütülmesi gerekmektedir. Geleneksel bakım yaklaşımları, reaktif ve periyodik yöntemlere dayandığından, arızaların önceden tahmin edilmesi konusunda yetersiz kalabilmektedir. Bu durum, operasyonel kesintilere, yüksek bakım maliyetlerine ve güvenlik risklerine neden olmaktadır.

Günümüzde, kestirimci bakım (Predictive Maintenance, PdM) teknikleri, makine öğrenmesi (Machine Learning-ML) ve yapay zeka (AI) tabanlı analiz yöntemleri ile entegre edilerek, havacılık sektöründe önemli bir dönüşüm yaratmaktadır. Kestirimci bakım, hava araçlarının çeşitli sensörlerden elde edilen büyük ölçekli verilerini analiz ederek, potansiyel arızaları önceden tespit etmeyi ve bakım süreçlerini optimize etmeyi amaçlamaktadır. Bu sayede, operasyonel süreklilik sağlanırken, bakım maliyetleri de önemli ölçüde azaltılmaktadır. Dünya çapında Airbus, Boeing, General Electric ve Lockheed Martin gibi büyük havacılık firmaları, kestirimci bakım teknolojilerine yönelik önemli yatırımlar yapmakta ve operasyonel güvenliği artırmak amacıyla veri odaklı analiz yöntemlerini kullanmaktadır. Bununla birlikte, literatürdeki mevcut çalışmaların büyük bir bölümü ticari yolcu uçakları ve askeri hava araçlarına odaklanmış olup, İHA sistemlerinde kestirimci bakım uygulamalarının geliştirilmesi konusunda sınırlı sayıda araştırma bulunmaktadır.

İHA sistemleri için bakım süreçleri genellikle periyodik kontroller ve reaktif müdahaleler üzerine kurulmuş olup, bu durum hem beklenmedik arızaların önlenmesini zorlaştırmakta hem de operasyonel verimliliği düşürmektedir. Özellikle uçuş sırasında meydana gelen arızalar, İHA'ların görev başarısını doğrudan etkileyerek maliyetli bakım süreçlerine ve operasyonel aksamalara neden

olabilmektedir. Geleneksel yöntemler, genellikle sınırlı veri analitiğine dayandığından, sensörlerden elde edilen büyük veriyi etkin bir şekilde işleyememekte ve arıza tahmin süreçlerinde yeterli hassasiyeti sağlayamamaktadır. Bu noktada, denetimsiz derin öğrenme (Deep Learning-DL) algoritmalarının İHA sistemlerine entegrasyonu, veri odaklı kestirimci bakım yaklaşımlarına önemli bir yenilik getirmektedir.

Denetimsiz DL teknikleri, sensörlerden elde edilen verileri analiz ederek anomali tespiti yapabilmekte ve arızaları henüz kritik hale gelmeden önce tahmin edebilmektedir. Geleneksel denetimli öğrenme yöntemlerinden farklı olarak, etiketlenmiş veri gereksinimi duymadan çalışabilmesi, denetimsiz öğrenme algoritmalarını daha ölçeklenebilir ve uygulanabilir hale getirmektedir. Bu bağlamda, Long Short-Term Memory (LSTM) ve Convolutional Neural Network (CNN) gibi modern DL algoritmalarının yanı sıra otoenkoderler (Autoencoders) ve Generative Adversarial Networks (GANs) gibi denetimsiz öğrenme yöntemleri, İHA sensör verilerinden anlamlı kalıpların çıkarılmasını ve kestirimci bakım süreçlerinin etkinleştirilmesini sağlamaktadır. Bu algoritmalar, büyük ölçekli ve zaman serisi formatındaki verileri analiz ederek, İHA sistemlerinin operasyonel güvenliğini artırmayı ve bileşenlerin kalan faydalı ömürlerini (KFÖ) tahmin etmeyi mümkün kılmaktadır.

Bu tez çalışmasının temel amacı, insansız hava aracı (İHA) pervanelerinde oluşan yapısal arızaların titreşim verisinden erken tespiti için iki tamamlayıcı veri odaklı yaklaşımı geliştirmek ve aynı multikopter platformunda karşılaştırmalı olarak değerlendirmektir. Birinci yaklaşım, gövdenin ağırlık merkezine yerleştirilen tek bir ivmeölçerden çıkarılan istatistiksel özniteliklerle pervane arızalarını sınıflandıran klasik makine öğrenmesi yöntemlerine; ikinci yaklaşım ise titreşimin zaman-frekans temsilleri üzerinde etiketli veriye gereksinim duymadan erken evre anomalileri belirleyen denetimsiz derin öğrenmeye dayanmaktadır. KFÖ tahmini ve belirsizlik değerlendirmesi ise tezin kapsamı dışında tutulmuş; otoenkoder yeniden yapılandırma hatasının bir sağlık göstergesi olarak kullanılabileceği bu yön, gelecek çalışmalara yönelik bir öneri olarak değerlendirilmiştir.

Bu amaç doğrultusunda tez kapsamında aşağıdaki temel araştırma sorusuna yanıt aranmıştır:

“Gerçek zamanlı olarak kablosuz biçimde toplanan titreşim verileri kullanılarak geliştirilen bütünleşik denetimli ve denetimsiz öğrenme yaklaşımı, İHA pervanelerinde hem bilinen arıza türlerinin güvenilir şekilde sınıflandırılmasını hem de daha önce görülmemiş erken evre anomalilerin etiketli veriye ihtiyaç duyulmaksızın tespit edilmesini sağlayabilir mi?”

İHA itki sistemlerinde pervane kaynaklı arızalar ani performans kaybına ve düşüşe yol açabilmekte; periyodik ve reaktif bakım yaklaşımları bu arızaları erken evrede yakalamakta yetersiz kalmaktadır. Bununla birlikte, döner kanatlı İHA'lara özgü, farklı arıza türü ve şiddetlerini sistematik biçimde içeren etiketli veri kümeleri sınırlıdır. Dolayısıyla ele alınan temel problem, tek bir titreşim sensöründen elde edilebilen veriden, pervane sağlığının hem bilinen arıza sınıflarına göre sınıflandırılabilirdiği hem de etiket gerektirmeden erken evre anomalilerinin tespit edilebildiği güvenilir bir izleme çerçevesinin geliştirilmesidir.

Belirtilen problem doğrultusunda tezin araştırma hedefleri sırasıyla (i) döner kanatlı bir İHA üzerinde, farklı pervane arıza türü ve şiddetlerini kontrollü koşullarda içeren titreşim veri kümelerinin oluşturulması, (ii) Ağırlık merkezine yerleştirilen tek bir ivmeölçerden çıkarılan istatistiksel özniteliklerle klasik makine öğrenmesi sınıflandırıcılarının pervane arızalarını ayırt etmedeki başarımının değerlendirilmesi ve (iii) Etiketli veriye gereksinim duymadan, titreşimin zaman–frekans temsilleri üzerinde erken evre anomalileri tespit eden denetimsiz bir derin öğrenme modelinin geliştirilmesi olarak tanımlanmıştır.

Tez yedi bölümden oluşmaktadır. Giriş bölümünün ardından, Bölüm 1'de İHA'larda arıza tespiti, kestirimci bakım, KFÖ tahmini ve anomali tespitine ilişkin literatür incelenmekte ve araştırma boşlukları belirlenmektedir. Bölüm 2'de insansız hava araçlarının tanımı ve sınıflandırılması, Bölüm 3'te arıza tespiti yöntemleri ile yapay zekâ tabanlı yaklaşımlar ele alınmaktadır. Bölüm 4, çalışmada kullanılan İHA platformunu, deney düzeneğini ve gerçek zamanlı veri toplama sürecini tanıtan materyal bölümüdür. Bölüm 5'te önerilen iki yöntem (klasik makine öğrenmesi ve denetimsiz derin öğrenme) ayrıntılı olarak açıklanmakta, Bölüm 6'da elde edilen bulgular sunulurken tartışılmakta ve Bölüm 7'de genel sonuçlar ile gelecek çalışma önerileri verilmektedir.

1. GENEL BİLGİLER VE LİTERATÜR ÇALIŞMASI

İHA'lar, arama-kurtarma, lojistik, tarım ve benzeri birçok alanda giderek daha yaygın bir şekilde kullanılmaktadır. Ancak, kullanım alanlarının çeşitliliğine rağmen, İHA'ların güvenlik ve güvenilirlik seviyeleri, insanlı hava araçlarına kıyasla daha düşük kalmaktadır. Bunun temel nedenlerinden biri, gerçek zamanlı izleme ve hızlı karar alma kapasitelerinin sınırlı olmasıdır. Özellikle karmaşık ve dinamik ortamlarda, bu sınırlamalar İHA'ların operasyonel etkinliğini ve güvenliğini olumsuz yönde etkileyerek, insan operatörlere olan bağımlılıklarını sürdürmelerine yol açmaktadır. İHA'lardaki arızalar genel olarak üç ana kategoriye ayrılmaktadır: (i) mekanik, (ii) elektriksel ve (iii) iletişim kaynaklı arızalar (Fourlas ve Karras, 2021). Bu arızalar içinde mekanik sistemlerde meydana gelenler, uçuş güvenliği açısından daha kritik bir önem taşımaktadır. Zira bu tür arızalar, doğrudan çarpışma veya kaza riskini artırmaktadır. Literatürde yapılan çalışmalar, İHA kazalarının yaklaşık %67'sinin mekanik arızalardan kaynaklandığını ve bu arızaların %53'ünün itki sisteminde, özellikle rotor ve pervane gibi ana bileşenlerde meydana geldiğini ortaya koymaktadır (Franco vd., 2007; Ghasri vd., 2021; Man vd., 2022). Bu tür kritik arızaların önüne geçebilmek ve İHA'ların operasyonel güvenilirliğini artırabilmek amacıyla tahmine dayalı bakım sistemleri önemli bir çözüm olarak öne çıkmaktadır. “US20170166328A1” ve “US2022204170A1” numaralı patentlerde tanımlandığı üzere, uçuş verilerinden özellik çıkarımı yaparak, birden fazla sınıflandırıcı aracılığıyla bileşenlerin durumlarını analiz eden ve bu analizleri birleştirerek bileşenlerin gelecekteki performanslarını tahmin eden yöntemler, İHA'ların güvenilirliğini artırmada önemli bir rol oynayabilir. Bu tür sistemler sayesinde, özellikle mekanik arızaların önceden tespit edilerek önlenmesi mümkün olacak, böylece İHA operasyonlarının daha güvenli ve etkin bir şekilde gerçekleştirilmesi sağlanabilecektir.

İHA genel olarak sabit kanatlı, döner kanatlı ve hibrit İHA'lar olmak üzere üç ana kategoriye ayrılmaktadır. Sabit kanatlı İHA'lar, geleneksel uçaklar gibi, ileri yönlü hareket sırasında kaldırma kuvveti üreten sert kanat yapılarına sahiptir. Aerodinamik açıdan yüksek verimliliğe sahip olmaları nedeniyle düşük enerji tüketimi ile uzun mesafeleri kat edebilmekte ve uzun süre havada kalabilmektedirler. Bu özelliklerinden dolayı geniş ölçekli haritalama, gözetleme ve izleme gibi menzil ve dayanıklılığın

kritik olduđu görevlerde yaygın olarak kullanılmaktadırlar. Döner kanatlı İHA'lar ise dikey kalkış prensibiyle çalışarak, havada sabit durabilme, hassas manevra yapabilme ve dar alanlarda kalkış-iniş gerçekleştirebilme yeteneklerine sahiptir. Bu üstün hareket kabiliyetleri sayesinde tarımsal uygulamalar (Türkseven vd., 2016), haritalama çalışmaları (Çoşkun, 2012), orman yangınlarıyla mücadele (Skorput vd., 2016), arama-kurtarma operasyonları (Shakhathreh vd., 2019) ve teslimat hizmetleri (Liu vd., 2022) gibi çeşitli alanlarda yaygın olarak kullanılmaktadırlar. Hibrit İHA'lar ise sabit kanatlı ve döner kanatlı İHA'ların avantajlarını birleştiren yenilikçi bir sistem olarak öne çıkmaktadır. Bu araçlar, genellikle dikey kalkış ve iniş (Vertical Takeoff and Landing-VTOL) kabiliyeti ile sabit kanatlı yapıdaki uzun menzil ve yüksek hız avantajını bir araya getirmektedir. Böylece hem uzun süreli uçuş gerektiren görevlerde hem de sınırlı alanlarda operasyon yapmayı gerektiren senaryolarda etkin bir şekilde kullanılabilirler. Hibrit İHA'lar, askeri keşif-gözetleme, insani yardım operasyonları, tarımsal izleme ve sınır güvenliği gibi geniş bir kullanım yelpazesine sahiptir ve son yıllarda bu alandaki teknolojik gelişmeler hızla artmaktadır.

İHA mekanik arızaların tespit edilmesi ve önlenmesi amacıyla kullanılan veriler, genellikle titreşim, sıcaklık, akım tüketimi ve voltaj gibi kritik parametreleri içermektedir (Ozkat vd., 2023). Özellikle titreşim verileri, rotor dengesizliği ve yatak aşınmaları gibi mekanik problemlerin erken teşhisinde önemli bir rol oynar. Bu tür arızalar zamanında tespit edilmediğinde, hızla ciddi boyutlara ulaşarak uçuş güvenliğini tehdit edebilir (Balestrieri vd., 2021). Sıcaklık verileri, motorun termal performansını ve çalışma koşullarını izleyerek, aşırı ısınmaya bağlı arızaların önlenmesine katkı sağlamaktadır. Akım tüketimi ve voltaj verileri ise motorun elektriksel yüklenmesini ve enerji kullanımını analiz ederek, performans düşüşlerinin nedenlerini anlamada kritik bir veri kaynağıdır. Mekanik arızaların öngörülmesi ve önlenmesi için en etkili yaklaşımlardan biri KFÖ analizidir (Ozkat, 2024). KFÖ süreci, mühendislik sistemlerinin güvenilirliğini artırmak amacıyla bileşenlerin sağlık durumlarını sürekli olarak değerlendiren bir yöntemdir. Bu süreçte, sistemin mevcut durumunu analiz etmek ve potansiyel arızaları belirlemek için sağlık göstergeleri (Health Indicators) kullanılmaktadır. Sağlık göstergeleri, genellikle titreşim, sıcaklık, akım tüketimi, voltaj ve basınç gibi fiziksel büyüklüklerden türetilmektedir. Bununla birlikte, sağlık göstergeleri yalnızca mevcut sistem durumunun analizi için değil, aynı

zamanda gelecekte meydana gelebilecek arızaların öngörülmesi amacıyla da kullanılmaktadır (Laloix vd., 2019).

KFÖ tahmini, bir sistemin veya bileşenin ne kadar süreyle işlevselliğini sürdürebileceğini öngörmeye yönelik kritik bir yaklaşımdır. KFÖ tahmini, temel olarak sağlık göstergelerinin analizine dayanmakta olup, zaman serisi analizi, ML ve DL tabanlı algoritmalar bu süreçte yaygın olarak kullanılmaktadır. Örneğin, Wang vd. (2020) tarafından yürütülen bir çalışmada, ML tabanlı algoritmaların KFÖ tahmini üzerindeki etkisi detaylı olarak incelenmiştir. Bununla birlikte, KFÖ tahminine yönelik çalışmaların büyük bir kısmı genel mühendislik sistemlerine odaklanırken, İHA sistemleri özelinde gerçekleştirilen araştırmaların literatürde sınırlı olduğu ve bu alanda daha kapsamlı çalışmalara ihtiyaç duyulduğu görülmektedir. İHA'lar, yüksek manevra kabiliyeti, değişken çevresel koşullar ve karmaşık operasyonel gereksinimler nedeniyle KFÖ analizine yönelik farklı zorluklar sunmakta olup, bu bağlamda geliştirilecek özgün yöntemler, sistem güvenilirliğini artırmada önemli katkılar sağlayacaktır.

İHA'lara yönelik KFÖ tahmini alanındaki mevcut çalışmalar incelendiğinde (Tablo 1), batarya ve mekanik bileşenlerin durum değerlendirmesi için farklı veri odaklı yöntemlerin kullanıldığı görülmektedir. Reddy vd. (2024) çalışmasında, batarya KFÖ tahmini için Rastgele Orman (Random Forest-RF) algoritmaları kullanılarak enerji yönetimi stratejilerinin iyileştirildiği ve uçuş süresi optimizasyonu sağlandığı belirtilmiştir. Petritoli vd. (2018) tarafından gerçekleştirilen bir çalışmada ise, Monte Carlo Simülasyonu çerçevesinde olasılıksal modelleme kullanılarak İHA'ların kestirimci bakım süreçleri optimize edilmiş, böylece bakım periyotlarının daha etkin planlanması sağlanmıştır.

Özkat vd. (2023) tarafından yapılan çalışmada, İHA'ların titreşim verilerine dayalı olarak KFÖ tahmini için LSTM modeli kullanılmış ve "ortalama tepe frekansı" adı verilen yeni bir özellik tanımlanmıştır. Benzer şekilde, Zahra vd. (2021) tarafından yapılan araştırmada, sinir ağı tabanlı bir yaklaşım benimsenerek, İHA tahrik sistemlerinin zaman serisi verilerindeki karmaşık ilişkileri modelleme yoluyla KFÖ tahmini gerçekleştirilmiştir. Çalışmada, LSTM ağı kullanılarak sağlık göstergesi (HI) tahmini yapılmış ve anormallik tespiti ile KFÖ hesaplamalarında başarılı sonuçlar elde edilmiştir.

Mansouri vd. (2017), farklı uçuş koşulları altında bataryaların KFÖ tahminini gerçekleştirmek için destek vektör regresyonu, çok katmanlı algılayıcı ve gelişmiş ağaç tabanlı algoritmalar gibi çeşitli ML yöntemlerini karşılaştırarak batarya ömrü kestiriminde etkinliği değerlendirmiştir. Eleftheroglou vd. (2019) ise, İHA'ların Lityum-Polimer bataryalarının deşarj gerilimine dayalı KFÖ tahmini için Gradient Boosted Trees, Bayesian Sinir Ağları ve Non-Homogeneous Hidden Semi Markov Modelleri gibi farklı yaklaşımlar kullanarak model performanslarını karşılaştırmıştır.

Liao vd. (2023) çalışmasında, elektrikli İHA'ların batarya sağlığını yönetmek için veri odaklı artımsal bir tahmin yöntemi önerilmiş olup, Stokastik Konfigürasyon Ağı (Stochastic Configuration Network- SCN) tabanlı modelin CEEMDAN yöntemi ile entegre edilerek tahmin doğruluğunun artırıldığı gösterilmiştir. Bu tür veri odaklı modeller, İHA operasyonlarının güvenilirliğini artırırken, bakım maliyetlerini optimize etmeye yönelik önemli katkılar sağlamaktadır.

Tablo 1. Kalan Faydalı Ömür Çalışmaları

Makale	Metodoloji	Uygulama Alanı
Mansouri vd. 2017	GBT	Batarya
Petritoli vd., 2018	Simülasyon	İHA Sistemleri
Eleftheroglou vd., 2019	K-Means Clustering	Lityum-Polimer Batarya
Zahra vd., 2021	LSTM	İHA Tahrik Sistemleri
Özkat vd., 2023	LSTM	İHA Sistemleri
Liao vd., 2023	DRSCN	Batarya
Reddy vd., 2024	RF	Batarya

Anomali tespiti, bir sistemin normal işleyişinde meydana gelen beklenmedik sapmaların belirlenmesi süreci olup, sistem güvenliği ve operasyonel sürekliliğin sağlanması açısından kritik bir rol oynamaktadır. Geleneksel anomali tespit yöntemleri çoğunlukla istatistiksel analiz ve temel veri işleme tekniklerine dayanırken, son yıllarda DL algoritmalarının entegrasyonu, tespit süreçlerinde daha yüksek doğruluk ve duyarlılık elde edilmesini sağlamıştır. Özellikle sağlık göstergelerine dayalı anomali tespiti üzerine yapılan araştırmalar, erken uyarı sistemlerinin geliştirilmesine önemli katkılar sunmaktadır. Bu bağlamda, Chen vd. (2021) tarafından gerçekleştirilen bir çalışmada, DL tabanlı bir anomali tespit modelinin İHA sistemlerindeki etkinliği değerlendirilmiş, bu yaklaşımın anormallikleri erken aşamada tespit edebilme yeteneği vurgulanmıştır. Anomali tespitine yönelik gelişmiş yöntemlerin, İHA'ların

operasyonel güvenilirliğini artırma ve olası arızaların önlenmesi noktasında önemli bir potansiyel sunduğu görülmektedir.

İHA'lar için anomali tespiti için çeşitli veri odaklı yaklaşımlar geliştirilmiştir (Tablo 2). Lu vd. (2017) çalışmasında, İHA motor sıcaklıklarının eşik değerlerini aşmasını önlemek amacıyla DS18B20 sıcaklık sensörleri kullanılarak pekiştirmeli öğrenme tabanlı bir sistem geliştirilmiş ve anomali tespiti sonucunda otomatik iniş mekanizması uygulanmıştır. Keipour vd. (2021) tarafından önerilen Gerçek Zamanlı Anomali Tespit Sistemi'nde, Recursive Least Squares yöntemi kullanılarak geniş bir hava aracı yelpazesinde uçak davranışlarındaki anomaliler başarıyla tespit edilmiştir. Bu sistem, %88,23 doğruluk ve %86,36 hassasiyet ile farklı uçuş aktüatörü arızalarını içeren yeni bir hata tespit veri seti sunmuştur.

Jia vd. (2023) tarafından gerçekleştirilen çalışmada, İHA uçuş verilerinde anomali tespiti için Destek Vektör Makineleri (Support Vector Machines-SVM) tabanlı hibrit bir yaklaşım kullanılmış, böylece durum değişim süreçlerindeki yanlış alarmlar minimize edilmiştir. Benzer şekilde, Zhong vd. (2021) çalışmasında, LSTM tabanlı bir model ile İHA uçuş verilerindeki uzamsal-zamansal ilişkiler analiz edilerek, anomali tespit performansı artırılmıştır. Pan vd. (2020) tarafından gerçekleştirilen çalışmada ise yarı gözetimli destek vektör makinesi (S3VM) kullanılarak aktif öğrenme ile desteklenmiş bir sınıflandırma yöntemi önerilmiş, böylece etiketli veri az olduğunda bile başarılı anomali tespiti sağlanmıştır.

Daha gelişmiş DL tabanlı yaklaşımlar incelendiğinde, Xiaowei (2023) çalışmasında CNN-SVM tabanlı bir yöntem önerilmiş ve halka açık İHA anomali veri seti kullanılarak modelin hesaplama süresi optimize edilmiştir. CNN ile zaman serisi formatına dönüştürülen veriler, daha sonra SVM ile işlenerek hata tanıma başarımı artırılmış ve önerilen modelin yüksek doğruluk sağladığı belirlenmiştir. Titouna vd. (2020) tarafından geliştirilen yöntem, Kullback-Leibler Divergence (KLD) ve Yapay Sinir Ağları (Artificial Neural Networks-ANN) kombinasyonu ile iç ve dış sensör verileri arasındaki farklılıkları değerlendirerek, hatalı ölçüm yapan İHA'ları başarıyla tespit etmiştir.

Özkat (2024) çalışmasında, İHA'ların pervane arızalarını erken aşamada tespit etmek için dalgacık saçılımı tabanlı LSTM otoenkoder modeli geliştirilmiş ve DJI M600 İHA'sı üzerinde test edilmiştir. Çalışmada, titreşim verileri kullanılarak arızalar yaklaşık 280. saniyede başarılı şekilde öngörülmüş, bu da yöntemin yüksek doğruluğa

sahip olduğunu göstermiştir. Bu tür gelişmiş anomali tespit modelleri, İHA sistemlerinin daha güvenli ve verimli çalışmasını sağlamaya yönelik önemli katkılar sunmaktadır.

Tablo 2. Anomali Tespiti Çalışmaları

Makale	Metodoloji	Uygulama Alanı
Lu vd., 2017	LSTM	Motor
Pan vd., 2020	S3VM	İHA Yüzeyi
Titouna vd., 2020	KLD + YSA	İç ve Dış Yüzey
Keipour vd., 2021	RLS	Yelpaze
Zhong vd., 2021	LSTM	Uçuş Verisi
Jia vd., 2023	SVM	Uçuş Verisi
Xiaowei, 2023	CNN + SVM	İHA Sistemleri
Özkat, 2024	LSTM	Pervane

Son yıllarda bilgisayar teknolojilerindeki ilerlemeler ve büyük veri analitiğindeki gelişmeler, İHA'larda anomali tespiti için veriye dayalı yöntemlerin kullanımını yaygınlaştırmıştır. Geleneksel sensör tabanlı donanımsal yaklaşımların sınırlamalarına karşın, veriye dayalı yöntemler, büyük miktardaki sensör verisini işleyerek dinamik uçuş koşullarına uyum sağlayabilmekte ve daha hassas, ölçeklenebilir çözümler sunabilmektedir. Bu yaklaşımlar, denetimli öğrenme (etiketli verilerle eğitilen modeller) ve denetimsiz öğrenme (verideki gizli yapıları keşfetmeye odaklanan algoritmalar) gibi ML tekniklerini içermektedir. ML, verilerden öğrenerek karar alabilen algoritmalar geliştirirken, DL bu süreci daha karmaşık ve çok katmanlı yapılarla gerçekleştirerek anomali tespitinde daha yüksek doğruluk oranları elde edilmesine olanak tanımaktadır. Özellikle denetimsiz DL algoritmaları, geçmiş verilerden öğrenerek anomali tespiti ve KFÖ analizlerinde kritik bir rol oynamaktadır. Örneğin, Saied vd. (2017) çalışmasında, çok rotorlu bir İHA'nın motorlarındaki ve rotorlarındaki sorunları tespit etmek ve teşhis etmek için SVM sınıflandırıcısı ile arızaya dayanıklı aktif kontrol yaklaşımı kullanılmıştır. Altinors vd. (2021) tarafından yapılan bir araştırmada, motor hasarını tespit etmek amacıyla ses sinyali analiz yöntemleri geliştirilmiş ve Karar Ağaçları (Decision Trees-DT), SVM ve k-en yakın komşu (kNN) algoritmaları ile yüksek doğruluk oranlarına ulaşılmıştır. Mustafa vd. (2024) ise, titreşim, sıcaklık, akım tüketimi ve voltaj sensör verilerini RF yöntemiyle işleyerek %94,7 doğruluk oranına ulaşmış ve RF yönteminin dinamik uçuş koşullarında güvenilir ve ölçeklenebilir bir çözüm sunduğunu göstermiştir. Bununla

birlikte, denetimli ML algoritmalarının performansı büyük ölçüde etiketlenmiş verilerin kalitesine ve miktarına bağımlıdır (Nasteski, 2017). Etiketleme sürecinin manuel olarak gerçekleştirilmesi gerektiğinde zaman alıcı ve maliyetli olması, denetimli yöntemlerin yaygın kullanımını kısıtlayan önemli bir faktördür. Ayrıca, etiketlenmiş verinin yetersizliği, denetimli öğrenme algoritmalarının genelleme kapasitesini sınırlayabilmekte ve model doğruluğunu olumsuz yönde etkileyebilmektedir (Adadi, 2021). Bu nedenle, denetimsiz veya yarı denetimli öğrenme yaklaşımlarının geliştirilmesi, İHA'larda anomali tespitinin daha etkili bir şekilde gerçekleştirilmesine katkı sağlayabilecek önemli bir araştırma alanı olarak öne çıkmaktadır.

Denetimsiz DL, etiketlenmemiş verilerden gizli kalıpları ve anomalileri belirlemeyi amaçlayan bir yaklaşımdır (Usama vd., 2019). Özellikle DL tabanlı denetimsiz yöntemler, karmaşık ve yüksek boyutlu veri yapılarını analiz etme konusunda üstün bir performans sergilemektedir. Örneğin, Jeon vd. (2023) çalışmasında, İHA'ların görev açısından kritik operasyonları sırasında pervanelerde veya motorlarda meydana gelen yapısal anomalilerin tespitine odaklanılmıştır. Tez kapsamında, düzenli uçuş verilerinden karmaşık özellikleri çıkarmak amacıyla uzun kısa süreli bellek (LSTM) tabanlı otoenkoder modeli kullanılmış ve uçuş sırasında yapısal anomalilerin doğru bir şekilde tespit edilmesi sağlanmıştır. Benzer şekilde, "CN114757086A" numaralı patente, çok rotorlu İHA'ların KFÖ tahmin edebilmek için yapay sinir ağı (ANN) tabanlı bir model geliştirilmiştir. Bu sistem, batarya voltajı, akım, motor gaz seviyesi gibi zaman serisi verileri ile sıcaklık, yük ağırlığı ve uçuş hızı gibi dış çevre faktörlerini birleştirerek İHA'nın kalan kullanım süresini tahmin etmektedir. Bununla birlikte, Kizito vd. (2021) çalışmasında, kısa süreli gözlem dizileri verildiğinde KFÖ tahmini için uygun bir amaç fonksiyonu ve hedef oluşturma yaklaşımı içeren yeni bir LSTM mimarisi geliştirilmiştir. Zhang (2023) tarafından yapılan çalışmada ise, rüzgar türbinlerinin titreşimlerini tahmin etmek amacıyla tekrarlayan sinir ağı (Recurrent Neural Networks-RNN) ile güçlendirilmiş bir LSTM modeli önerilmiş ve LSTM-RNN yaklaşımının geleneksel ML sınıflandırıcılarından daha üstün performans sergilediği gösterilmiştir. Lu vd. (2017) çalışmasında ise, motor anomalilerini tespit etmek için DL tabanlı bir sistem önerilmiş ve motor sıcaklıklarının artış hızını izleyerek arıza tahmini gerçekleştirilmiştir. İHA'lar tarafından üretilen yüksek boyutlu verilerin analizinde en sık kullanılan yaklaşımlardan biri de Evrişimli

Sinir Ağları (CNN) tabanlı yöntemlerdir. Venkatesh vd. (2022), fotovoltaik modüllerde meydana gelen çeşitli arızaların sınıflandırılması amacıyla CNN tabanlı bir yöntem sunmuş ve bu tekniğin gerçek zamanlı anomali tespiti için güçlü bir araç olduğunu ortaya koymuştur. CNN'lerin hiyerarşik özellik çıkarma yeteneği, İHA verilerinin işlenmesi için özellikle avantaj sağlamaktadır. Omer vd. (2023) çalışmasında ise, kızılötesi sensörlerden elde edilen termal görüntülerin DL modelleriyle işlenerek güneş hücrelerindeki anomalilerin tespit ve sınıflandırılabilirdiği gösterilmiştir. Bu yaklaşım, sensör füzyonunun önemini vurgulamakta ve DL yöntemlerinin farklı veri kaynaklarından anlamlı çıkarımlar yapma potansiyelini ortaya koymaktadır.

Tez kapsamında önerilen çalışma; tek bir gövde merkezine yerleştirilen ivmeölçerden elde edilen gerçek zamanlı titreşim verileri üzerinde, kontrollü olarak oluşturulan farklı pervane arıza türleri ve şiddetlerini kapsayan özgün bir veri kümesi kullanması, bu veri üzerinde hem klasik makine öğrenmesi hem de denetimsiz derin öğrenme yaklaşımlarını aynı deneysel çerçevede karşılaştırmalı olarak değerlendirmesi, sinyal işleme ve derin öğrenme yöntemleriyle İHA pervane arıza tespitine uyarlaması bakımından literatüre özgün katkılar sunmaktadır.

İHA pervane arızalarının titreşim verisinden tespitini iki tamamlayıcı yaklaşımla ele alması bakımından literatürdeki çalışmalardan ayrılmaktadır. Birinci yaklaşımda, klasik makine öğrenmesi sınıflandırıcılarıyla bilinen pervane arıza türleri etiketli veri üzerinden ayırt edilmekte; ikinci yaklaşımda ise denetimsiz derin öğrenme ile etiketli veriye gereksinim duymadan erken evre anomalileri tespit edilmektedir. Otoenkoder yeniden yapılandırma hatasının bir sağlık göstergesi olarak kullanılacağı KFÖ tahmini ile belirsizlik değerlendirmesi ise gelecek çalışmalara yönelik bir araştırma yönü olarak konumlandırılmaktadır. Böylece sağlık göstergelerinin analizine dayalı olarak hem bilinen arızaların sınıflandırılması hem de erken evre anomalilerin yakalanması bir arada değerlendirilmekte ve sistem güvenilirliğinin artırılması hedeflenmektedir.

Literatürde, İHA'ların güvenlik ve güvenilirliğini artırmaya yönelik çeşitli çalışmalar yapılmış olmasına rağmen, hala çözülmesi gereken bazı kritik araştırma boşlukları bulunmaktadır. Bu bağlamda, mevcut literatürde tespit edilen temel araştırma eksiklikleri aşağıda sıralanmıştır;

- Çoklu sensör verilerinin entegrasyonu, İHA'lardan elde edilen farklı tipteki sensör verilerinin (titreşim, motor, uçuş, çevresel veriler vb.) entegre

edilmesini gerektiren ve literatürde hala çözülmesi gereken önemli bir zorluk olarak öne çıkan bir konudur. Farklı kaynaklardan gelen verilerin farklı zaman ölçeklerinde ve formatlarda olması, entegrasyon sürecini karmaşıktırmakta ve farklı sensörlerden elde edilen bilgilerin eş zamanlı olarak analiz edilmesini ve birleştirilmesini zorlaştırmaktadır.

- Özgün ve kapsamlı veri setlerinin eksikliği, literatürde rotor-kanatlı İHA'lara özgü açık kaynaklı veri setlerinin yetersizliği olarak dikkat çekmektedir. Mevcut veri setleri genellikle sınırlı uçuş senaryolarını içermekte, bu durum ise algoritmaların genelleme kapasitesini kısıtlamaktadır.
- Denetimsiz öğrenme algoritmalarının İHA anomali tespiti üzerindeki potansiyeli yeterince araştırılmamıştır. Literatürdeki çalışmalar çoğunlukla denetimli ML yöntemlerine odaklanmış olsa da, denetimsiz öğrenme, etiketlenmiş verilere ihtiyaç duymaksızın geniş veri setleri üzerinde gizli kalıpları ve anomalileri tespit etme yeteneğiyle önemli bir avantaj sunmaktadır. Özellikle DL tabanlı denetimsiz yöntemlerin, yüksek boyutlu ve karmaşık veri yapılarını analiz etme kapasitesi, anomali tespiti ve sistem güvenilirliği açısından dikkate değer bir potansiyel taşımaktadır.
- Gerçek zamanlı sistem eksikliği, literatürdeki çalışmaların büyük bir bölümünün çevrimdışı analizlere odaklandığını göstermektedir. Ancak, İHA'ların operasyonel yapısı gereği, anomali tespiti ve performans değerlendirmelerinin gerçek zamanlı olarak gerçekleştirilmesi büyük önem taşımaktadır. Gerçek zamanlı çalışan sistemlerin eksikliği, özellikle karmaşık uçuş senaryolarında İHA'ların etkinliğini sınırlamakta ve operasyonel güvenliği olumsuz yönde etkilemektedir. Bu nedenle, gerçek zamanlı veri işleme ve anomali tespitine yönelik çözümler geliştirilmesi, İHA'ların güvenilirliğini ve operasyonel verimliliğini artırmak için kritik bir gereklilik olarak öne çıkmaktadır.

2. İNSANSIZ HAVA ARAÇLARI

Bu bölüm, İHA tanımını, sınıflandırılmasını ve teknik özelliklerini titizlikle ele alarak kapsamlı bir inceleme sunmaktadır. Literatür taraması çerçevesinde, İHA kavramının tarihsel gelişimi, öncü prototipleri ve terminolojileri kronolojik bir perspektif içinde değerlendirilmiştir. İHA'ların askeri ve sivil havacılık alanlarındaki kullanımı, düzenleyici otoriteler ve endüstri standartları ekseninde incelenerek, bu sistemlerin gelişimiyle birlikte getirilen düzenleyici aksiyonlar ve sınırlamalar izah edilmiştir. Tanımlama çerçevesinde, İHA'ların operasyonel kullanım senaryoları ele alınarak, mevcut terminolojiye katkı sağlayacak teknik değerlendirmeler yapılmıştır.

İHA'ların sınıflandırılması ve teknik analizinde, sabit kanatlı, döner kanatlı ve hibrit sistemler ayrıntılı bir şekilde ele alınmıştır. Sabit kanatlı İHA'ların aerodinamik prensipleri, menzil avantajları ve uzun süreli keşif-gözetleme görevlerindeki etkinliği tartışılırken, döner kanatlı İHA'ların VTOL yeteneği, yüksek manevra kabiliyeti ve kısa mesafeli görevlerdeki avantajları detaylandırılmıştır. Hibrit İHA'ların her iki sistemin avantajlarını birleştiren yapıları, operasyonel esneklikleri ve otonom uçuş yetenekleri kapsamında incelenmiş, gelecekteki uygulamaları ve potansiyel kullanım alanları değerlendirilmiştir.

Quadracopter sistemleri ise döner kanatlı İHA'ların en yaygın alt türlerinden biri olarak ele alınmış, çok rotorlu yapıları, stabilizasyon mekanizmaları ve otonom kontrol algoritmaları açısından kapsamlı bir şekilde değerlendirilmiştir. Bu sistemlerin özellikle güvenlik, lojistik, afet yönetimi ve tarım gibi alanlardaki artan kullanım oranları göz önünde bulundurularak, performans parametreleri ve operasyonel etkinlikleri karşılaştırmalı olarak incelenmiştir.

2.1. İnsansız Hava Aracı Tanımı

İHA, insan müdahalesi olmadan veya uzaktan kontrol edilerek havada görev yapabilen hava araçlarıdır. Günümüzde İHA'lar, başta savunma sanayi olmak üzere tarım, lojistik, afet yönetimi, haritalama, çevresel izleme ve hava tahmini gibi birçok farklı alanda kullanılmaktadır. Gelişen teknolojiyle birlikte, İHA'ların kullanım alanları genişlemiş, sensör teknolojileri, AI destekli veri işleme sistemleri ve otonom uçuş kabiliyetleri ile daha gelişmiş bir seviyeye ulaşmıştır (Cheng vd., 2023).

İHA'ların ortaya çıkışı, havacılık tarihinin erken dönemlerine kadar uzanmaktadır. İlk İHA kavramı, askeri keşif ve gözetleme ihtiyaçlarına dayanarak geliştirilmiştir. Ancak günümüzde İHA'ların kullanım alanı sadece askeri operasyonlarla sınırlı kalmamış, birçok farklı sektörde kritik bir teknoloji haline gelmiştir. İHA sistemleri, farklı görev tanımlarına uygun şekilde tasarlanarak hem operasyonel verimliliği artırmakta hem de maliyet avantajı sağlamaktadır.

İHA fikri, uçuş teknolojisinin gelişmesiyle birlikte ortaya çıkmış ve ilk olarak askeri alanda uygulanmıştır (Keane, ve Carr, 2013). 20. yüzyılın başlarında, uçak teknolojisinin hızla gelişmesiyle birlikte, pilot riski olmadan keşif ve saldırı gerçekleştirebilecek hava araçları geliştirme fikri ön plana çıkmıştır.


İHA'ların ilk örnekleri, uzaktan kumanda edilebilen veya önceden belirlenmiş rotalarda uçabilen İHA olarak geliştirilmiştir. Bu alandaki ilk önemli girişimlerden biri, 1916 yılında İngiltere tarafından geliştirilen Aerial Target adlı radyo kontrollü uçaktır (Udeanu vd., 2016). Bu araç, dönemin teknolojisi göz önünde bulundurulduğunda, temel bir İHA konsepti olarak değerlendirilebilir. Aynı dönemde, Amerika Birleşik Devletleri'nde (ABD) geliştirilen Kettering Bug (Şekil 1.), önceden belirlenmiş bir rotada uçabilen ve belirli bir hedefe yönlendirilebilen ilk insansız uçaklardan biri olarak kayıtlara geçmiştir. Ancak, bu tür sistemler henüz tam anlamıyla operasyonel hale gelememiş ve savaşın sona ermesiyle birlikte projeler durdurulmuştur.



Şekil 1. Kettering Bug (National Museum)

İkinci Dünya Savaşı, insansız sistemlerin geliştirilmesi açısından önemli bir dönüm noktası olmuştur. Almanya tarafından geliştirilen V-1 uçan bombası (Şekil 2.),

otonom uçuş gerçekleştirebilen ilk füzelerden biri olarak tarihe geçmiştir (Zaloga, 2011). Aynı dönemde, ABD ve İngiltere tarafından geliştirilen hedef dronları, savaş pilotlarının eğitiminde kullanılmıştır. Bu dronlar, düşman uçaklarına karşı hava savunma sistemlerinin test edilmesinde kritik bir rol oynamıştır.



Şekil 2. V-1 Uçan Bomba (U.S. Air Force photo)

Soğuk Savaş dönemi, İHA keşif ve istihbarat amaçlı kullanımının yaygınlaştığı bir dönem olmuştur. 1950’li yıllarda ABD tarafından geliştirilen Ryan Firebee (Şekil 3.) gibi insansız keşif uçakları, düşman bölgelerinden istihbarat toplamak amacıyla kullanılmıştır (Prisacariu, 2017). Bu dönemde İHA’ların menzili, irtifa kabiliyetleri ve uçuş süresi önemli ölçüde artırılmıştır.



Şekil 3. Ryan Firebee (San Diego Air and Space)

1970’li ve 1980’li yıllarda, özellikle İsrail tarafından geliştirilen İHA, savaş sahasında etkin bir şekilde kullanılmaya başlanmıştır. Scout (Şekil 4.) gibi sistemler, keşif ve gözetleme görevlerinde başarı sağlamış ve diğer ülkeler tarafından da benimsenmiştir.



Şekil 4. Scout (IAI)

1990’lı yıllarda, gelişmiş sensör teknolojileri, Küresel Konumlandırma Sistemi (Global Positioning System-GPS) destekli uçuş sistemleri ve dijital veri iletimi gibi yenilikler, İHA'ların operasyonel yeteneklerini önemli ölçüde artırmıştır (Eisenbeiss, 2004). ABD tarafından geliştirilen RQ-1 Predator (Şekil 5.), bu dönemin en dikkat çekici İHA sistemlerinden biri olmuş ve ilk kez silahlandırılarak modern savaş alanında aktif olarak kullanılmaya başlanmıştır. Predator İHA'ları, istihbarat, keşif ve hedef tespit görevlerinde büyük bir başarı elde etmiş ve zamanla daha gelişmiş modelleri üretilmiştir.




Şekil 5. RQ-1 Predator (Intelligence Resource Program)

2000’li yıllarda, İHA teknolojisi askeri alandan sivil alanlara yayılmaya başlamıştır. Ticari ve endüstriyel kullanım alanları genişlemiş, özellikle havadan görüntüleme, tarımsal analiz, sınır güvenliği ve yangın söndürme gibi uygulamalarda İHA’ların kullanımı hız kazanmıştır. Günümüzde, AI destekli sistemlerle donatılmış İHA, otonom uçuş yetenekleri kazanmış, büyük veri analizi ve nesnelerin interneti (IoT) ile entegre edilebilir hale gelmiştir (Motlagh vd., 2017).


Türkiye, bu teknolojik dönüşüme hızla adapte olmuş ve özellikle savunma sanayinde büyük bir atılım gerçekleştirmiştir (Kasapoğlu ve Kırdemir, 2018). 2000’li yılların başında İHA konusunda bağımsız bir ekosistem oluşturma hedefiyle yola çıkan TUSAŞ (Türk Havacılık ve Uzay Sanayii A.Ş.) ve Baykar, kısa sürede uluslararası alanda söz sahibi olan şirketler haline gelmiştir.

TUSAŞ, İHA projelerine 2000’li yıllarda Anka programı ile başlamış, 2013 yılında Anka-S (Şekil 6.) modelinin ilk uçuşunu gerçekleştirmiştir. Anka platformu, Türk Silahlı Kuvvetleri envanterine girerek keşif, gözetleme ve istihbarat faaliyetlerinde önemli bir rol üstlenmiştir. 2021 yılında geliştirilen Aksungur (Şekil 6.), uzun menzilli ve ağır yük taşıma kapasitesiyle Türkiye’nin stratejik İHA arasında yerini almıştır.



Şekil 6. a) Anka b) Aksungur


Baykar, 2007 yılında Bayraktar Mini İHA (Şekil 7.) ile ilk yerli İHA üretimini gerçekleştirmiş, 2014 yılında ise Bayraktar TB2’nin (Şekil 7.) ilk teslimatlarını yaparak Türkiye’nin İHA alanında dışa bağımlılığını büyük ölçüde azaltmıştır. Bayraktar TB2, özellikle Suriye, Libya, Karabağ ve Ukrayna’da sergilediği operasyonel başarılarla küresel çapta büyük bir ilgi görmüş ve Türkiye’yi İHA pazarında önemli bir oyuncu haline getirmiştir.



Şekil 7. a) Bayraktar Mini İHA b) Bayraktar TB2

Bugün Türkiye, İHA sektöründe dünya liderlerinden biri haline gelmiştir. TUSAŞ, Baykar ve diğer firmaların geliştirdiği sistemler, yalnızca Türk Silahlı Kuvvetleri tarafından değil, aynı zamanda onlarca ülke tarafından tercih edilmektedir. Türkiye, dünya silahlı insansız hava aracı (SİHA) pazarında 65%'a yaklaşan bir paya sahip olup, bu alanda ABD, İsrail ve Çin ile rekabet eden en güçlü ülkelerden biri konumundadır. Özellikle Bayraktar TB2, dünya çapında en çok ihracatı yapılan SİHA sistemlerinden biri haline gelmiş ve Türkiye'yi savunma sanayiinde küresel bir marka haline getirmiştir.

Geleceğe bakıldığında, Türkiye'nin İHA alanındaki liderliğini sürdürerek daha gelişmiş platformlar, AI destekli otonom sistemler ve yeni nesil hava araçları üretmeye devam etmesi beklenmektedir. Bu platformların en büyük örnekleri Bayraktar Kızılelma (Şekil 8.) ve Anka III (Şekil 8.) çalışmalarıdır. Bu gelişmeler, Türkiye'nin savunma sanayindeki bağımsızlığını güçlendirmekle kalmayıp, küresel İHA pazarındaki etkisini daha da artıracaktır.



Şekil 8. a) Bayraktar Kızılelma b) Anka III

Tarihsel Süreçlerin dışında incelediğimizde İHA, teknolojik gelişmelerle birlikte günümüzde geniş bir kullanım alanına sahip olmuştur. İlk etapta sadece askeri amaçlarla geliştirilen bu sistemler, günümüzde sivil havacılık, tarım, lojistik, çevre izleme, afet yönetimi ve sanayi gibi birçok farklı alanda kullanılmaktadır (Ozkat, 2024). İHA'ların yaygınlaşmasının temel nedenlerinden biri, gelişmiş sensör sistemleri, AI tabanlı analiz yöntemleri, uzun menzilli iletişim altyapıları ve otonom uçuş yeteneklerinin gelişmiş olmasıdır. Özellikle dijital veri işleme teknolojilerinin ilerlemesi ve maliyetlerin düşmesi, İHA'ların yalnızca devletler ve büyük şirketler tarafından değil, küçük ölçekli işletmeler ve bireyler tarafından da erişilebilir hale gelmesini sağlamıştır (Fan vd., 2020; Rao vd., 2016).

İHA'ların en yoğun kullanıldığı alanlardan biri askeri ve savunma sanayisidir. Keşif, gözetleme, istihbarat toplama ve hedef belirleme gibi görevlerde uzun yıllardır kullanılan İHA'lar, günümüzde silahlandırılmış versiyonlarıyla saldırı operasyonlarında da etkin bir şekilde görev yapmaktadır. Hedefleri hassas bir şekilde belirleyerek yüksek vuruş kabiliyetine sahip olmaları, düşük maliyetle operasyon gerçekleştirebilmeleri ve pilot kaybı riskini ortadan kaldırmaları, askeri operasyonlarda İHA'ların kullanımını giderek yaygınlaştırmaktadır (Suresh ve Ghose, 2012; Wang vd., 2020). Özellikle terörle mücadele ve asimetrik savaş koşullarında, İHA'lar düşük radar izleri, uzun havada kalış süreleri ve yüksek hassasiyetleri sayesinde büyük bir avantaj sağlamaktadır (Wellig vd., 2018). Modern savaş doktrinlerinde insansız sistemlerin giderek daha önemli hale gelmesiyle birlikte, İHA'lara entegre edilen AI destekli karar mekanizmaları, gelişmiş optik ve termal görüntüleme sistemleri ve sinyal istihbarat sistemleri sayesinde bu hava araçlarının stratejik önemi giderek artmaktadır (Gaire, 2023; Nguyen vd., 2021; Liu vd., 2020).

Sivil havacılık alanında da İHA'ların kullanımı giderek yaygınlaşmaktadır. Özellikle hava trafiğinin yönetilmesi, haritalama, şehir planlaması ve altyapı denetimleri gibi alanlarda İHA'ların sağladığı verimlilik, bu teknolojinin gelecekte daha fazla benimsenmesine yol açmaktadır. İHA'ların yüksek çözünürlüklü kameralar ve sensör sistemleri ile donatılması, büyük ölçekli şehir planlama projelerinde altyapının haritalandırılmasını ve havadan analiz edilmesini mümkün kılmaktadır (Yılmaz ve Ulvi, 2022; Erenoglu vd., 2018). Ayrıca, hava kirliliği ve trafik yoğunluğu gibi faktörlerin izlenmesinde de İHA giderek daha fazla rol oynamaktadır (Villa vd., 2016; Alharbi vd., 2023). Gelecekte, otonom hava taksileri ve şehir içi drone

taşımacılığı gibi uygulamalarla birlikte, İHA'ların sivil havacılık sektöründeki etkisinin daha da artacağı öngörülmektedir (Mohsan vd., 2023).

Tarım sektörü, İHA kullanımının en hızlı yaygınlaştığı alanlardan biridir. Özellikle büyük ölçekli tarım arazilerinde verimliliği artırmak amacıyla kullanılan İHA'lar, bitki sağlığının izlenmesi, hassas ilaçlama, gübreleme ve sulama gibi işlemlerde büyük avantajlar sağlamaktadır (Neupane ve Baysal-Gurel, 2021; Chen vd., 2021; Song vd., 2020). Geleneksel yöntemlere kıyasla daha düşük maliyetle, daha hızlı ve hassas bir şekilde tarım arazilerinin izlenmesini sağlayan bu sistemler, tarımsal üretimin sürdürülebilirliğine önemli katkılar sunmaktadır. Multispektral kameralar ve termal görüntüleme sensörleri ile donatılmış İHA'lar, bitkilerdeki hastalıkların erken teşhis edilmesini sağlayarak zirai kayıpların önlenmesine yardımcı olmaktadır (Abbas vd., 2023). Bunun yanı sıra, tarım alanlarında zararlı böcek ve haşere tespitine yönelik olarak kullanılan İHA, çevre dostu ve düşük maliyetli mücadele yöntemleri geliştirilmesine de katkıda bulunmaktadır (Velusamy vd., 2021).

Afet yönetimi ve acil durum müdahalelerinde İHA'ların kullanımı giderek yaygınlaşmaktadır. Deprem, sel, yangın ve diğer doğal afetlerde, İHA'lar hızlı bir şekilde bölgeye ulaşarak anlık görüntüler sağlayabilmekte, arama kurtarma ekiplerinin yönlendirilmesine yardımcı olmaktadır. Afet anında hasar tespiti yapabilen ve tehlikeli bölgelerde görev alabilen İHA'lar, can kayıplarını en aza indirmek için kritik bir öneme sahiptir. Özellikle geniş alanlara yayılan afetlerde, geleneksel keşif yöntemlerine kıyasla daha hızlı veri toplayabilen bu sistemler, koordinasyon süreçlerini kolaylaştırmakta ve müdahale sürelerini kısaltmaktadır. Orman yangınlarının tespit edilmesi ve söndürülmesi süreçlerinde de İHA büyük bir avantaj sağlamaktadır (Sudhakar vd., 2020). Termal kameralar sayesinde yangının başlangıç noktasının belirlenmesi ve yangının yayılım yönünün tespit edilmesi, müdahale ekiplerinin daha etkili bir şekilde hareket etmesine imkân tanımaktadır (Sadi, 2020).

Lojistik ve taşımacılık sektöründe de İHA'ların kullanımı giderek yaygınlaşmaktadır (Hossain vd., 2022). Özellikle e-ticaret sektöründe büyük firmalar tarafından test edilen drone taşımacılığı uygulamaları, gelecekte teslimat sürelerini önemli ölçüde kısaltmayı hedeflemektedir. Kargo taşımacılığına yönelik geliştirilen İHA sistemleri, özellikle ulaşımın zor olduğu kırsal bölgelerde büyük bir kolaylık sağlamaktadır. Acil ilaç ve tıbbi malzeme teslimatlarında da İHA'ların kullanılması, sağlık hizmetlerinin erişilebilirliğini artırmakta ve özellikle afet bölgelerinde kritik bir

özüm sunmaktadır (Walia vd., 2018). Elektrikli ve evre dostu olmaları nedeniyle karbon salınımını azaltmaya yönelik özmler sunan İHA, lojistik sektöründe sürdürülebilirlik açısından önemli bir rol oynamaktadır.

evresel izleme ve bilimsel araştırmalar alanında da İHA yaygın olarak kullanılmaktadır. Hava kirliliğı, su kalitesi, ekolojik dengenin korunması gibi konularda veri toplamak amacıyla kullanılan İHA'lar, evresel değıřimlerin izlenmesine ve bilimsel analizlerin yapılmasına olanak tanımaktadır (Danilov vd., 2015). Özellikle kutup bölgelerinde, okyanuslarda ve volkanik bölgelerde yapılan araştırmalarda, zorlu hava koşullarına dayanıklı İHA önemli veriler elde edilmesini sağlamaktadır. Orman ekosistemlerinin korunması, kaçak avcılığın önlenmesi ve doğal yaşamın izlenmesi gibi alanlarda da İHA'lar etkin bir şekilde kullanılmaktadır (Sangeetha vd., 2024).

İHA teknolojisi, günümüzde hızla gelişmeye devam etmekte olup yeni nesil otonom sistemlerle desteklenerek daha güvenilir, etkili ve düşük maliyetli hale getirilmektedir. AI ve ML tabanlı yazılımlarla entegre edilen İHA'lar, çok daha karmařık görevleri yerine getirebilir hale gelmiştir. Özellikle AI destekli görüntü işleme sistemleri sayesinde, İHA'lar anlık olarak evresini analiz edebilmekte, nesne tanıma ve hedef takibi gibi görevleri başarıyla gerçekleştirebilmektedir (Cheng vd., 2023; Liu vd., 2020; Wang vd., 2019). Gelecekte, İHA'ların daha gelişmiş sensörlerle donatılarak şehir içi ulaşım, güvenlik sistemleri ve akıllı şehir uygulamalarında yaygın bir şekilde kullanılacağı öngörülmektedir.

2.2. İnsansız Hava Araları Sınıflandırılması


İHA, farklı operasyonel ihtiyaçlara ve kullanım alanlarına göre eřitlendirilmiş hava platformlarıdır. Tasarım özellikleri, uçuř süresi, menzil, boyut, görev kapasitesi ve kontrol yöntemlerine göre sınıflandırılan İHA'lar, günümüzde hem askeri hem de sivil alanlarda yaygın olarak kullanılmaktadır. Teknolojik ilerlemeler, İHA'ların giderek daha karmařık görevleri yerine getirebilmesini sağlarken, farklı türdeki sistemlerin gelişmesine de olanak tanımıştır. Bu bağlamda, İHA'lar farklı kategorilere ayrılarak değıerlendirilmekte ve kullanım amaçlarına göre özel tasarımlar içermektedir.

İHA'ların sınıflandırılması, genellikle uçuř süresi, menzil, irtifa, kullanım amacı ve aerodinamik yapı gibi kriterler göz önüne alınarak yapılmaktadır. Bu

kriterlere bağılı olarak, sabit kanatlı, döner kanatlı ve hibrit sistemler gibi çeşitli İHA türleri ortaya çıkmıştır.

2.2.1. Sabit Kanatlı İnsansız Hava Araçları

Sabit kanatlı İHA (Şekil 9.), aerodinamik prensiplere dayalı olarak tasarlanmış ve geleneksel uçaklara benzer şekilde çalışan sistemlerdir. Kanat yüzeyleri boyunca oluşan kaldırma kuvveti sayesinde havada uzun süre kalarak, yüksek hızda ve geniş menzilde uçuş gerçekleştirebilme kapasitesine sahiptirler (Shi vd., 2019). Bu tür İHA'lar, motor veya itki sistemlerinin sağladığı ileri doğru hareket ile kaldırma kuvvetini sürekli olarak koruyarak verimli bir uçuş profili oluştururlar (Lee vd., 2021). Yüksek verimlilikleri ve uzun uçuş süreleri nedeniyle, genellikle keşif, gözetleme, haritalama, tarım ve lojistik gibi operasyonel süreklilik gerektiren görevlerde tercih edilmektedirler.



Şekil 9. Sabit Kanatlı İnsansız Hava Aracı

Sabit kanatlı İHA'ların en belirgin avantajlarından biri yüksek yakıt verimliliğidir (Garg, 2022). Döner kanatlı sistemlere kıyasla daha az enerji tüketerek daha uzun mesafeleri kat edebilmeleri, bu tür hava araçlarını uzun süreli keşif ve gözetleme görevleri için ideal hale getirmektedir (Zhou vd., 2020). Sabit kanatlı İHA'lar, hava akımlarını ve aerodinamik kaldırma kuvvetini etkin bir şekilde kullanarak havada kalış süresini maksimuma çıkarabilmektedir (Khan ve Nahon, 2015). Bu özellik, özellikle askeri keşif-gözetleme operasyonları, sınır güvenliği, geniş arazi haritalama çalışmaları ve tarım alanlarının izlenmesi gibi faaliyetlerde büyük bir avantaj sağlamaktadır.

Bununla birlikte, sabit kanatlı sistemlerin genellikle daha yüksek hızlara ulaşabilmesi, bu hava araçlarını stratejik gözetleme, acil müdahale ve veri toplama görevleri için uygun hale getirmektedir (El Adawy vd., 2023). Örneğin, yüksek irtifalarda faaliyet gösteren uzun menzilli İHA'lar, yüzlerce kilometrelik alanı tek bir uçuşta tarayarak büyük ölçekli istihbarat ve keşif operasyonlarında kritik rol oynamaktadır. Özellikle yüksek çözünürlüklü görüntüleme ve sinyal istihbaratı toplama (SIGINT) yetenekleri sayesinde, modern savunma ve güvenlik alanlarında vazgeçilmez platformlar haline gelmişlerdir (Frasca vd., 2023; Aşcı, 2024; Mohsan vd., 2023).

Geniş kullanım alanına sahip olan sabit kanatlı İHA'lar, uzaktan algılama teknolojileriyle entegre edildiklerinde, tarım ve çevresel izleme gibi alanlarda da büyük bir etki yaratmaktadır. Tarım sektöründe kullanılan sabit kanatlı İHA'lar, multispektral ve hiperspektral görüntüleme sistemleri sayesinde mahsul sağlığını analiz etmek, su kaynaklarını verimli kullanmak ve zirai ilaçlama süreçlerini optimize etmek için kullanılmaktadır (Flores vd., 2017; Lu vd., 2020; Brito vd., 2019). Aynı şekilde, iklim değişikliği ve doğal afetlerin takibi gibi çevresel analizlerde de sabit kanatlı İHA sistemlerinden yararlanılmaktadır.

Sabit kanatlı İHA'lar, geleneksel uçaklar gibi pist gereksinimi duyabilmekte veya belirli fırlatma sistemleriyle havalandırılabilir. Büyük ölçekli ve uzun menzilli sabit kanatlı İHA'lar genellikle havaalanları veya özel pistlerden kalkış yaparken, küçük ölçekli taktik İHA'lar katapult sistemleri veya rampalı fırlatma mekanizmaları ile havalandırılabilir. Örneğin, askeri keşif İHA'ları çoğu zaman taşınabilir fırlatma sistemleri veya mancınık benzeri mekanizmalarla çalıştırılmakta ve operasyon bölgesine göre mobil olarak konumlandırılabilir. İniş sırasında ise bazı sabit kanatlı İHA'lar paraşüt sistemleri veya karın üstüne iniş yapabilen kaygan yüzey mekanizmaları kullanmaktadır.

Son yıllarda, VTOL yeteneğine sahip sabit kanatlı İHA'ların geliştirilmesi, bu hava araçlarının esnekliğini artırmıştır (Zhou vd., 2020). Geleneksel sabit kanatlı sistemlerin pist gereksinimi ve iniş alanı ihtiyacı, VTOL teknolojisi sayesinde büyük ölçüde ortadan kalkmaktadır (Rehan vd., 2022). Hibrit sistemler olarak da adlandırılan bu İHA'lar, döner kanatlı İHA'ların dikey kalkış avantajını sabit kanatlı hava araçlarının uzun menzil ve verimlilik özellikleriyle birleştirerek, daha geniş operasyonel kullanım imkânı sunmaktadır.

2.2.2. Döner Kanatlı İnsansız Hava Araçları

Şekil 10'da gösterilen Döner kanatlı İHA'lar helikopter benzeri aerodinamik prensiplere dayalı olarak çalışan ve bir veya birden fazla rotor sistemi aracılığıyla kaldırma kuvveti üreten sistemlerdir yeteneğine sahip olmaları sayesinde, sabit kanatlı İHA'lara kıyasla daha dar alanlarda operasyon gerçekleştirebilir ve karmaşık görevleri başarıyla yerine getirebilirler (Segui-Gasco vd., 2014; Lee vd., 2021). Özellikle iniş-kalkış için pist gereksinimi duymamaları, bu sistemleri şehir içi operasyonlar, acil durum müdahaleleri ve hassas manevralar gerektiren görevler için son derece uygun hale getirmektedir.



Şekil 10. Döner Kanatlı İnsansız Hava Aracı

Döner kanatlı İHA'ların en büyük avantajlarından biri yüksek manevra kabiliyeti ve belirli bir noktada sabit uçuş yapabilme (hovering) yeteneğidir (Verbeke ve Schutter, 2018; Wang vd., 2018). Sabit bir noktada havada durabilmeleri, gözetleme, keşif, sınır güvenliği ve hedef takip gibi görevlerde büyük bir avantaj sağlamaktadır. Örneğin, şehir içi güvenlik operasyonlarında, olay yerinde anlık veri toplanması gereken arama-kurtarma çalışmalarında ve hassas tarım uygulamalarında döner kanatlı sistemlerin kullanımı giderek yaygınlaşmaktadır. Yüksek çözünürlüklü kameralar, termal görüntüleme sistemleri ve lazer tarama sensörleriyle donatılan döner kanatlı İHA'lar, belirli bir alanın detaylı bir şekilde analiz edilmesine ve anlık veri toplanmasına olanak tanımaktadır (Messaoudi vd., 2023; Hyypä vd., 2020). Bu yönüyle, trafik yönetimi, çevresel izleme, yangın gözetleme ve altyapı denetimi gibi uygulamalarda kritik bir rol üstlenmektedirler.

Ancak, döner kanatlı İHA'ların menzil ve uçuş süresi açısından bazı kısıtlamaları bulunmaktadır. Sabit kanatlı sistemler aerodinamik kaldırma kuvveti

sayesinde daha az enerji harcayarak uzun mesafeler kat edebilirken, döner kanatlı sistemler havada kalmak için sürekli olarak rotorlarını çalıştırmak zorundadır (Prior, 2010). Bu durum, batarya veya yakıt tüketimini artırarak, menzil ve havada kalış süresini sınırlandırmaktadır (Betti Sorbelli vd., 2024). Elektrikli modeller genellikle 30 ila 60 dakika arasında uçuş süresine sahipken, yakıt bazlı hibrit sistemler daha uzun operasyon süreleri sunabilmektedir. Ancak, gelişen batarya teknolojileri ve enerji verimliliğini artıran motor sistemleri sayesinde döner kanatlı İHA'ların uçuş süresi ve operasyonel etkinliği her geçen gün artmaktadır. Özellikle hidrojen yakıt hücreleri ve güneş enerjisi destekli sistemlerin geliştirilmesi, döner kanatlı İHA'ların daha uzun süreler boyunca kesintisiz görev yapabilmesini mümkün kılacaktır (Gadalla ve Zafar, 2016; Morton vd., 2015).

Günümüzde döner kanatlı İHA'lar, platform tasarımına bağlı olarak farklı konfigürasyonlarda üretilmektedir. En yaygın modeller arasında Şekil 11.'de gözüken dört rotorlu (quadrotor), altı rotorlu (hexacopter) ve sekiz rotorlu (octocopter) sistemler yer almaktadır (Niemiec vd., 2018). Quadrotor sistemler, kompakt ve hafif yapılarıyla düşük maliyetli ve taşınabilir çözümler sunarken, hexacopter ve octocopter sistemler daha fazla taşıma kapasitesine ve güçlü stabilizasyon özelliklerine sahiptir (Gupte vd., 2012; Giribet vd., 2016; Zhu vd., 2020). Özellikle yüksek taşıma kapasitesi gerektiren lojistik operasyonlarda, tarımsal ilaçlama görevlerinde ve ağır sensör sistemlerinin entegre edilmesi gereken askeri keşif faaliyetlerinde altı ve sekiz rotorlu modeller tercih edilmektedir.



Şekil 11. a) Quadrotor, b) Hexacopter ve c) Octocopter

Döner kanatlı İHA'ların kullanım alanları giderek genişlemekte olup, lojistik ve kargo taşımacılığı, sağlık hizmetleri, afet yönetimi, tarım, savunma ve güvenlik sektörlerinde önemli bir yer edinmiştir. Son yıllarda büyük teknoloji firmaları, drone ile kargo teslimatı projeleri geliştirmekte ve şehir içi lojistik çözümlerinde döner

kanatlı sistemleri etkin bir şekilde kullanmaya başlamaktadır. Örneğin, e-ticaret sektöründeki hızlı teslimat süreçlerini optimize etmek amacıyla döner kanatlı İHA'lar test edilmekte ve büyük ölçekli pilot projeler yürütülmektedir (Ma vd., 2025). Sağlık alanında ise, acil tıbbi malzeme taşınması, kan ve organ nakli gibi kritik hizmetlerde döner kanatlı İHA'ların kullanımı büyük bir kolaylık sağlamaktadır (Scalea vd., 2021).

Afet yönetimi ve acil durum müdahalelerinde de döner kanatlı İHA'ların önemi giderek artmaktadır. Deprem, sel, yangın ve doğal afetlerde anlık görüntüleme yaparak kurtarma ekiplerine kritik veriler sunan bu sistemler, arama-kurtarma operasyonlarında hayati bir rol üstlenmektedir (Gomez ve Purdie, 2016). Yangın tespiti ve orman yangınlarının yayılım hızının belirlenmesi için kullanılan termal kameralarla donatılmış döner kanatlı İHA'lar, erken uyarı sistemleriyle entegre edilerek büyük çaplı felaketlerin önlenmesine katkı sağlamaktadır (Kinaneva vd., 2019).

Savunma sanayisinde döner kanatlı sistemlerin önemi her geçen gün artmaktadır. Askeri keşif ve gözetleme görevlerinde kullanılan döner kanatlı İHA'lar, küçük ölçekli taktik operasyonlardan sınır güvenliği görevlerine kadar geniş bir kullanım alanına sahiptir. Özellikle kentsel muharebe sahalarında, ani operasyon gerektiren durumlarda ve düşman unsurların tespiti için döner kanatlı sistemler kritik avantajlar sunmaktadır. Hafif, taşınabilir ve sessiz çalışan bu sistemler, yakın hava desteği, istihbarat toplama ve özel operasyonlar gibi görevlerde güvenlik güçleri tarafından etkin bir şekilde kullanılmaktadır. Son yıllarda, kamikaze İHA'lar (Şekil 12.) (dolaşan mühimmatlar) da savaş doktrinlerinde önemli bir yer edinmiştir. Döner kanatlı kamikaze İHA'lar, özellikle düşman unsurlarını hızlı ve nokta atışıyla etkisiz hale getirmek için geliştirilmiştir. Bu sistemler, keşif ve gözetleme yaparak hedefleri belirleyebilir ve ardından otonom veya manuel yönlendirme ile doğrudan hedefe dalarak imha edici bir etki yaratabilir (Park vd., 2019; Muda ve Sudarsono, 2019). Hafif ve taşınabilir yapıları sayesinde özel kuvvetler ve sınır güvenliği operasyonlarında etkili bir şekilde kullanılmaktadır (Palomba vd., 2022). Bu sistemlerin savunma sanayisindeki önemi giderek artmakta ve gelecekte daha gelişmiş, AI destekli, otonom sürü teknolojileri ile donatılmış döner kanatlı kamikaze İHA'ların askeri operasyonlarda daha fazla yer alması beklenmektedir (Agarwal vd., 2023).



Şekil 12. Kamikaze İnsansız Hava Aracı (STM Savunma)

AI ve otonom sistemlerin gelişimiyle birlikte döner kanatlı İHA'lar çok daha karmaşık ve bağımsız operasyonları gerçekleştirebilecek seviyeye ulaşmıştır (Javaid vd., 2023; Aibin vd., 2021). Otonom uçuş algoritmaları, gelişmiş nesne tanıma sistemleri ve sürü teknolojisiyle donatılan yeni nesil döner kanatlı İHA'lar, birbirleriyle koordineli bir şekilde çalışarak, geniş alanların aynı anda izlenmesini ve analiz edilmesini mümkün kılmaktadır (Chapala vd., 2016). Özellikle sürü İHA (Şekil 13.) teknolojisi, savunma sanayisinde yeni bir devrim yaratmakta ve AI destekli hava harbi konseptlerinin geliştirilmesini sağlamaktadır (Guitton, 2021).



Şekil 13. Sürü İnsansız Hava Araçları (MSI Turkish Defence,2020)

Döner kanatlı İHA'ların gelişimi, batarya teknolojileri, otonom yazılımlar, veri işleme sistemleri ve haberleşme altyapıları ile doğrudan ilişkilidir. Gelecekte, hızlı şarj edilebilen bataryalar, daha yüksek verimli motor sistemleri ve düşük enerji tüketimli uçuş algoritmaları sayesinde döner kanatlı İHA'ların menzil ve görev süreleri önemli

ölçüde artacaktır (Chittoor vd., 2021). Ayrıca, 5G ve uydu tabanlı haberleşme sistemlerinin entegrasyonu, döner kanatlı İHA'ların daha geniş alanlarda kesintisiz iletişim sağlayarak yüksek hassasiyetli operasyonlar gerçekleştirmesine olanak tanıyacaktır (Hosseini vd., 2019).

2.2.3. Hibrit İnsansız Hava Araçları

Hibrit İHA (Şekil 14.) sabit kanatlı ve döner kanatlı sistemlerin avantajlarını bir araya getiren yenilikçi hava platformlarıdır. VTOL yapabilen hem de sabit kanatlı uçakların sunduğu yüksek hız, uzun menzil ve yakıt verimliliği avantajlarını taşıyan bu sistemler, günümüzde havacılık sektöründe önemli bir yere sahiptir (Rehan vd., 2022). Geleneksel sabit kanatlı İHA'ların pist gereksinimi ve döner kanatlı sistemlerin menzil kısıtlamaları gibi dezavantajlarını ortadan kaldırarak daha esnek ve verimli bir uçuş kabiliyeti sunmaktadırlar (Dewi vd., 2015). Bu özellikleri sayesinde hibrit İHA'lar, askeri operasyonlar, keşif ve gözetleme görevleri, lojistik destek, acil durum müdahaleleri ve tarımsal uygulamalar gibi birçok farklı alanda kullanılmaktadır.



Şekil 14. Hibrit İnsansız Hava Aracı

Geleneksel sabit kanatlı İHA'lar, yüksek hızda uzun menzilli uçuş yapabilme avantajına sahip olsa da, kalkış ve iniş için pist veya fırlatma mekanizmalarına ihtiyaç duymaktadır. Öte yandan, döner kanatlı İHA'lar, dar alanlarda dikey kalkış ve iniş yapabilme avantajı sağlarken, menzil ve havada kalış süresi açısından daha sınırlıdır (Zhao ve Li, 2022). Hibrit İHA sistemleri, bu iki tasarım yaklaşımının avantajlarını birleştirerek, hem uzun menzilli uçuş yapabilme hem de dar alanlardan kalkış ve iniş

gerçekleştirme kapasitesine sahiptir (Saeed vd., 2015). Bu sayede, hem stratejik keşif ve gözetleme görevlerinde hem de ulaşılması zor bölgelerde operasyonel olarak büyük bir avantaj sağlamaktadır.

Hibrit İHA'ların en dikkat çeken özelliklerinden biri, geçiş uçuş yeteneğidir (transition flight). Geleneksel döner kanatlı İHA'lar, kalkıştan itibaren tamamen rotor sistemiyle çalışırken, sabit kanatlı sistemler ileri hareketle aerodinamik kaldırma kuvveti üretir. Hibrit İHA'lar ise dikey kalkış yaptıktan sonra sabit kanatlı uçuş moduna geçerek daha verimli ve uzun menzilli bir uçuş gerçekleştirebilir. Bu özellik, özellikle zorlu coğrafi koşullara sahip bölgelerde, deniz üzerinde ya da pist bulunmayan ortamlarda yapılan operasyonlarda büyük bir kolaylık sağlamaktadır (Delavarpour vd., 2021).

Bu sistemlerin operasyonel kabiliyeti, elektrik, içten yanmalı motorlar veya hibrit güç sistemleriyle sağlanmaktadır. Elektrikli modeller genellikle daha hafif, daha sessiz ve bakım gereksinimi daha düşük sistemler sunarken, içten yanmalı motorlar ya da hibrit yakıt sistemleri ile çalışan hibrit İHA'lar daha uzun menzil ve yüksek taşıma kapasitesine sahiptir (Recoskie vd., 2013; Bershadsky vd., 2016). Son yıllarda, hidrojen yakıt hücreleri ve güneş enerjisiyle çalışan hibrit sistemlerin geliştirilmesi, bu tür platformların sürdürülebilirlik ve verimlilik açısından daha fazla tercih edilmesini sağlamaktadır (Pan vd., 2019; El-Atab vd., 2021).

Hibrit İHA'lar, askeri alanda keşif, gözetleme, istihbarat toplama ve mühimmat taşıma görevlerinde aktif olarak kullanılmaktadır (Şekil 15). Özellikle sınır güvenliği, uzun süreli istihbarat toplama ve ani müdahale gerektiren operasyonlarda hibrit sistemler, geleneksel sabit ve döner kanatlı sistemlere kıyasla daha fazla operasyonel esneklik sağlamaktadır (Tariq vd., 2023). Hibrit İHA'lar ayrıca hava savunma sistemlerinden kaçınma, düşük radar izi sayesinde gizli operasyonlarda kullanılma ve savaş ortamında esnek manevralar gerçekleştirme yeteneğine de sahiptir (Liu vd., 2023). Bu nedenle, hibrit İHA konsepti, gelecekte insansız hava harbi doktrinlerinde önemli bir yer edinmesi beklenen bir teknoloji olarak görülmektedir.



Şekil 15. Bayraktar Kalkan (BAYKAR)

Sivil kullanım alanında ise hibrit İHA'lar, lojistik, kargo taşımacılığı, tarım ve çevresel izleme gibi alanlarda giderek daha fazla kullanılmaktadır. E-ticaret sektöründe hızlı teslimat süreçlerini optimize etmek için hibrit İHA'ların test edilmesi ve büyük ölçekli lojistik şirketleri tarafından bu sistemlerin kargo taşımacılığı için pilot projelerde kullanılması dikkat çekmektedir (Tatham vd., 2017). Özellikle şehir içi ve kırsal alanlar arasında taşımacılığı hızlandırmak için VTOL yeteneği sayesinde esnek çözümler sunan hibrit İHA'lar, ticari kullanımda gelecekte önemli bir rol üstlenecektir (Gu vd., 2017). Tarım alanında ise hava destekli ilaçlama, mahsul sağlığı analizi, verimlilik tahmini ve tarımsal sulama yönetimi gibi görevlerde hibrit sistemlerin sağladığı uzun menzil ve sabit nokta uçuş yetenekleri büyük avantaj sağlamaktadır (Bai vd., 2020). Ayrıca, çevresel izleme ve afet yönetimi alanında, geniş alanların hızlı bir şekilde taranması ve acil müdahale gerektiren durumlarda hızlı tepki verebilme yetenekleri ile hibrit İHA'ların kullanımı giderek yaygınlaşmaktadır.

Günümüzde hibrit İHA teknolojisinin gelişimi, AI destekli otonom uçuş algoritmaları, ileri sensör sistemleri ve gelişmiş haberleşme teknolojileri ile hız kazanmıştır (Patel vd., 2020). Otonom navigasyon sistemleri, uçuş esnasında hava koşullarına ve çevresel faktörlere otomatik olarak uyum sağlayarak daha güvenli ve verimli operasyonların gerçekleştirilmesine imkan tanımaktadır. AI tabanlı kontrol sistemleri sayesinde, bu İHA'lar insan müdahalesi olmadan karmaşık görevleri yerine getirebilir, anlık veri analizi yapabilir ve görev planlamalarını optimize edebilir. Özellikle uydu haberleşme sistemleri ve 5G destekli yüksek bant genişlikli veri aktarım teknolojileri, hibrit İHA'ların gerçek zamanlı veri paylaşımı yaparak koordineli operasyonlarda kullanılmasını sağlamaktadır (Abualsauod, 2022).

Gelecekte, hibrit İHA'ların menzil, hız, taşıma kapasitesi ve otonom uçuş yeteneklerinin daha da geliştirilmesi beklenmektedir. Gelişmiş malzeme teknolojileri sayesinde, daha hafif ve dayanıklı gövde yapıları ile enerji verimliliği artırılacak, batarya ve motor sistemlerindeki ilerlemelerle daha uzun süreli ve yüksek performanslı uçuşlar mümkün hale gelecektir. Ayrıca, hava-hava ve hava-yer etkileşimlerinde insanlı ve İHA ortak çalışabilen hibrit İHA sistemlerinin yaygınlaşması, savunma sanayisinde insansız hava harbinin geleceğini şekillendirecek önemli bir adım olacaktır.

3. İNSANSIZ HAVA ARAÇLARINDA ARIZA TESPİTİ

İHA güvenilirliği ve operasyonel sürekliliği, bakım süreçlerinin etkin bir şekilde yürütülmesine doğrudan bağlıdır. Bu bağlamda, arıza tespit yöntemlerinin doğru uygulanması ve bakım stratejilerinin sistematik biçimde yönetilmesi, İHA'ların performansını ve görev başarımını doğrudan etkilemektedir. Geleneksel bakım yaklaşımları genellikle arıza gerçekleşikten sonra müdahaleyi esas alırken, modern yöntemler daha çok arızayı önceden öngörmeyi ve sistemin bütünlüğünü sürdürülebilir kılmayı hedeflemektedir.

Reaktif ve önleyici bakım gibi klasik yaklaşımlar, belirli periyotlarda yapılan kontrol ve değişimlere dayanmakta; ancak bu yöntemler, arızaların görev esnasında ortaya çıkmasını tam anlamıyla engelleyememektedir. Bu nedenle, son yıllarda özellikle kestirimci ve proaktif bakım stratejileri ön plana çıkmıştır. Kestirimci bakım, sistem bileşenlerinden gerçek zamanlı olarak toplanan verilerin analiziyle arızaların önceden tahmin edilmesini amaçlar. Bu yaklaşımla, yalnızca arızaların öngörülmesi değil, aynı zamanda bakım maliyetlerinin azaltılması ve sistem kullanılabilirliğinin artırılması da mümkün olmaktadır.

İHA'lerden elde edilen uçuş dinamikleri, motor performansı, çevresel koşullar ve yapısal sağlık verileri, arıza tespiti süreçlerinde kritik bir rol oynamaktadır. Bu veriler, sistem bileşenlerinde meydana gelen yorgunluk, aşınma ve çevresel etkiler gibi faktörlerin modellenmesinde kullanılmakta; böylece bileşenlerin KFÖ bilimsel olarak tahmin edilebilmektedir. Bununla birlikte, sensör verilerinden elde edilen anormalliklerin tespiti, arıza ihtimallerinin önceden belirlenmesine katkı sağlamaktadır. Özellikle denetimsiz ML algoritmaları, etiketli veri gereksinimi olmaksızın olağandışı durumları saptamada etkili sonuçlar vermektedir.

AI destekli yaklaşımlar, İHA sistemlerinde arıza tespiti ve bakım süreçlerinin daha da ileriye taşınmasını mümkün kılmaktadır. ML ve DL algoritmaları, büyük hacimli uçuş verilerinin analizinde yüksek doğrulukta tahminler sunarak, geleneksel yöntemlere kıyasla daha esnek ve dinamik çözümler üretmektedir. Zaman, frekans ve zaman-frekans düzleminde gerçekleştirilen sinyal işleme teknikleri, özellikle titreşim, ses ve sıcaklık gibi fiziksel parametrelerin analizi yoluyla sistem davranışlarındaki değişimleri saptamada önemli katkılar sağlamaktadır.

DL alanında, ANN, LSTM yapıları ve oto-kodlayıcılar gibi modeller; karmaşık veri ilişkilerini öğrenme, zaman serisi verilerdeki örüntüleri keşfetme ve anormal durumları tespit etme konusunda yüksek başarı göstermektedir. Bu modellerin kullanımı, İHA'larda arıza tespiti ve kestirimci bakım süreçlerinin otomatikleştirilmesine ve optimize edilmesine olanak tanımaktadır.

3.1. Arıza Tespiti için Kullanılan Yöntemler

İHA, sahip oldukları karmaşık aerodinamik yapılar, entegre elektronik sistemler ve hassas mekanik bileşenler nedeniyle sürekli izleme ve düzenli bakım gerektiren sistemlerdir (Milidonis vd., 2023). Özellikle askeri ve sivil havacılık sektörlerinde kritik görevlerde kullanılan İHA'ların güvenilirliği, operasyonel sürekliliği ve uzun ömürlü olması, bu sistemlerin etkinliği açısından büyük önem taşımaktadır (Chaturvedi vd., 2019). Görev sırasında meydana gelebilecek beklenmedik bir arıza, yalnızca maliyet kaybına yol açmakla kalmaz, aynı zamanda stratejik operasyonların başarısız olmasına ve insan hayatının riske girmesine neden olabilir (Clothier vd., 2015; de Alvear Cárdenas ve de Visser, 2024). Bu nedenle, İHA'ların bakım süreçlerinin etkin bir şekilde yönetilmesi ve arızaların önceden tespit edilerek giderilmesi, havacılık sektöründe temel mühendislik konularından biri haline gelmiştir (Liu vd., 2024).

Bu bağlamda, İHA'larda meydana gelebilecek arızaların önceden tespit edilmesi, bakım süreçlerinin optimize edilmesi ve sistemlerin kesintisiz çalışmasını sağlamak amacıyla çeşitli arıza tespit yöntemleri geliştirilmiştir (Milidonis vd., 2023). Arıza tespit yöntemleri genel olarak reaktif bakım, önleyici bakım, kestirimci bakım ve proaktif bakım gibi farklı yaklaşımlar altında incelenmektedir (Petrinoli vd., 2018; Erbiyik, 2022). Bu yöntemler, İHA'ların operasyonel sürekliliğini artırmak, bakım maliyetlerini düşürmek ve güvenilirliklerini en üst seviyeye çıkarmak amacıyla uygulanmaktadır (Galar vd., 2020).

Reaktif bakım, bir sistemin arızalandıktan sonra onarılması esasına dayanmaktadır (Özgür-Ünlüakın vd., 2019). Geleneksel bakım yöntemlerinden biri olan bu yaklaşım, genellikle sistemlerin planlı bir şekilde izlenmediği veya arıza tespit mekanizmalarının yeterince gelişmiş olmadığı durumlarda uygulanmaktadır. Ancak, reaktif bakım stratejisi, İHA operasyonları açısından ciddi riskler taşımaktadır (Steen vd., 2019). Bir İHA'nın uçuş sırasında kritik bir arıza yaşaması, hem yüksek maliyetli

kayıplara hem de insan hayatını tehlikeye atabilecek durumlara yol açabilmektedir (Grzegorz vd., 2021). Bu nedenle, havacılık sektöründe reaktif bakım yerine, daha ileri düzeyde bakım stratejileri benimsenmiştir.

Önleyici bakım, sistemlerin belirli bir kullanım süresi veya uçuş saati baz alınarak bakım işlemlerinin planlanmasını içermektedir (Basri vd., 2017). Bu yaklaşımda, uçuş öncesi ve sonrası kontroller, belirli periyotlarla motor ve elektronik sistemlerin test edilmesi, sensörlerin ve mekanik bileşenlerin düzenli olarak gözden geçirilmesi gibi uygulamalar yer almaktadır (Eliaz ve Latanision, 2007). Önleyici bakım, reaktif bakıma kıyasla daha güvenli bir yaklaşım olsa da, arıza oluşmadan önce kesin bir tespit sağlanamadığı için bazı durumlarda gereksiz bileşen değişimleri ve beklenmeyen sistem arızaları ile karşılaşılabilir (Kinnison ve Siddiqui, 2013). Bu durum, bakım maliyetlerini artırabileceği gibi, sistemlerin planlanandan daha kısa sürede servis dışı kalmasına da neden olabilmektedir.

Geleneksel bakım stratejilerinin yetersizlikleri, modern İHA sistemlerinde kestirimci bakım (predictive maintenance) uygulamalarının geliştirilmesine yol açmıştır (Latorella ve Prabhu, 2017). Kestirimci bakım, büyük veri analitiği, ML ve AI destekli sistemler aracılığıyla, İHA'ların arızalanmadan önce durumunu analiz ederek bakım gereksinimlerini öngören bir yaklaşımdır (Zonta vd., 2020). Bu yöntem, uçuş sırasında toplanan verilerin analiz edilmesiyle sistemde meydana gelebilecek potansiyel arızaların önceden belirlenmesine olanak tanımaktadır. Özellikle titreşim analizleri, sıcaklık sensörleri, motor performans verileri, batarya durumu ve uçuş sırasında oluşan anormal durumlar kestirimci bakımın temel veri kaynaklarını oluşturmaktadır.

Kestirimci bakım sistemlerinde, uçuş sırasında veya yer kontrol istasyonlarında toplanan veriler gerçek zamanlı olarak analiz edilerek olası arızalar tahmin edilmektedir (Korvesis vd., 2018). Bu süreçte, ML tabanlı algoritmalar, geçmiş uçuş verilerini kullanarak anormal durumları tespit edebilmekte ve sistemlerde kritik bir hata meydana gelmeden önce ilgili bileşenin değiştirilmesi veya onarılması önerilmektedir. Örneğin, bir motor bileşeninde normalden daha yüksek sıcaklık artışı tespit edildiğinde, sistem olası bir aşınma veya elektriksel arıza konusunda önceden uyarıda bulunabilmektedir. Böylece, bakım ekipleri yalnızca gerekli bileşenleri değiştirerek maliyetleri optimize edebilmekte ve sistemin beklenmedik şekilde devre dışı kalmasının önüne geçebilmektedir.

Kestirimci bakımın en büyük avantajlarından biri, İHA sistemlerinde görev süresinin artırılması ve operasyonel sürekliliğin sağlanmasıdır (Daily ve Peterson, 2016). Geleneksel bakım yöntemlerinde olduğu gibi belirli periyotlarla bileşen değiştirmek yerine, gerçek zamanlı veriye dayalı analizlerle yalnızca gerektiğinde bakım yapılmakta ve böylece sistemlerin verimliliği maksimize edilmektedir. Havacılık sektöründe maliyetlerin büyük bir kısmı bakım ve onarım süreçlerinden kaynaklandığı için, kestirimci bakım uygulamaları hem ekonomik açıdan büyük bir tasarruf sağlamakta hem de uçuş güvenliğini artırmaktadır (Korvesis, 2017).

İHA'larda arıza tespiti için kullanılan bir diğer yöntem, veri tabanlı izleme ve analiz sistemleridir. Uçuş sırasında toplanan hava aracı telemetri verileri, motor durumu, kanat yapısındaki titreşimler, iniş takımlarının basınç değişimleri, pil sağlığı ve hava akış sensörleri gibi bilgiler, büyük veri analiz sistemleriyle işlenerek arıza tespiti için kritik bir kaynak oluşturmaktadır.

Bu bağlamda, dijital ikiz teknolojisi, arıza tespitinde giderek daha yaygın hale gelen bir yöntem olarak öne çıkmaktadır. Dijital ikiz yaklaşımı, bir İHA'nın fiziksel bileşenlerinin sanal bir kopyasının oluşturulması ve gerçek zamanlı uçuş verileri ile simülasyon ortamında modellenmesi esasına dayanmaktadır. Böylece, bir bileşenin çalışma ömrü boyunca nasıl bir aşınma ve yıpranma sürecine maruz kalacağı önceden tahmin edilebilmekte ve olası arızalar önceden belirlenerek gerekli bakım süreçleri optimize edilebilmektedir.

ML ve AI destekli sistemlerin entegrasyonu ile birlikte, anomali tespiti algoritmaları, İHA sistemlerinde daha hassas bir arıza tahmin süreci sunmaktadır. Özellikle denetimsiz öğrenme (unsupervised learning) yöntemleri, sistemde beklenmeyen veya normal dışı çalışma durumlarını belirleyerek mühendislerin erken müdahale etmesine olanak tanımaktadır. Bu yöntemler, arıza tespit sürecini manuel analizlere kıyasla çok daha hızlı ve doğru bir hale getirmektedir.

3.2. Kestirimci Bakım

Kestirimci bakım, ekipmanlardan elde edilen verilerin analiz edilerek modeller oluşturulmasını ve bu modellerle ekipmanların gelecekteki arızalarının tahmin edilmesini sağlayan bir bakım yöntemidir (Avcı ve Acir, 2020; Nunes vd., 2023). Bu yöntem, diğer bakım türlerine göre birçok avantaja sahiptir. Öncelikle, arızaların önceden tespit edilmesini sağlayarak düzeltici ve periyodik bakımdan daha verimli bir


yaklaşım sunar (Lu vd., 2019). Bu sayede, arızaların erken tespitiyle zamanında müdahale edilebilir ve üretim sürekliliği sağlanabilir. Ayrıca, kestirimci bakım, periyodik bakımdan daha az duruş süresi sağlar ve daha düşük maliyetli bir alternatif sunar (Selcuk, 2017). Ekipman ömrünün uzatılması da kestirimci bakımın önemli avantajlarından; arızaların erken tespiti, ekipmanların daha uzun süre verimli çalışmasını sağlar, bakım maliyetlerini azaltır ve işletme maliyetlerini düşürür (Zhu vd., 2019).

Ancak kestirimci bakımın bazı dezavantajları da vardır (Zhao vd., 2010). İlk olarak, yüksek başlangıç yatırım maliyetleri gelir (Franceschini ve Midali, 2019). Kestirimci bakım uygulamaları için özel ekipmanlar, yazılımlar ve eğitilmiş personel gereklidir; bu da diğer bakım yöntemlerine göre daha yüksek maliyetlere yol açabilir. Ancak, uzun vadede bu yatırımların karşılanması mümkündür ve kestirimci bakımın sağladığı avantajlar, maliyetleri hızla telafi edebilir. Bir diğer dezavantajı ise, kestirimci bakım uygulamalarının yanlış yapılması durumunda hatalı sonuçlar alınabilmesidir (zu Wickern, 2019). Bu sebeple, doğru ekipman ve yazılım seçimi ile veri analizi ve eğitilmiş personel gereklidir. Aksi takdirde, hatalı sonuçlar bakım maliyetlerini artırabilir ve ekipman ömrünü kısaltabilir (Nishat Toma ve Kim, 2020; Tandon ve Choudhury, 2005).

Düzeltilici bakım, ekipman arızaları meydana geldikten sonra yapılan tamir işlemlerini içerir ve genellikle en pahalı bakım türüdür (Sakib ve Wuest, 2018). Arızaların ortaya çıkmasını takiben yapılan bu tamirler, beklenmedik maliyetleri işletmelere getirebilir. Periyodik bakım ise, ekipmanların belirli zaman dilimlerinde düzenli olarak kontrol edilmesi ve bakımının yapılmasını içerir. Bu yöntem, potansiyel arızaların önceden tespit edilmesini sağlar ve düzeltilici bakıma kıyasla daha düşük maliyetlere yol açar (Certa vd., 2012).

Kestirimci bakım ise, verilerin analiz edilmesiyle ekipman arızalarının gelecekteki zamanlamalarını tahmin etmeyi hedefler (Daily ve Peterson, 2016). Bu yöntem, beklenmedik arızaları önlemeye ve ekipmanların sürekli çalışabilirliğini sağlamaya yöneliktir. Kestirimci bakımın maliyet açısından bakıldığında, düzeltilici bakım en yüksek maliyetli yöntemken, periyodik ve kestirimci bakım sırasıyla daha düşük maliyetlere sahiptir. Bu durum, düzenli bakım faaliyetlerinin maliyetleri kontrol altında tutarak beklenmedik tamir maliyetlerini engelleme potansiyeline sahip olmasından kaynaklanır (Takahashi, 2020).

Sonuç olarak, kestirimci bakım, diğer bakım türlerine göre daha etkili ve verimli bir yöntem olarak öne çıkmaktadır (Lee vd., 2020). Ancak, yüksek başlangıç yatırım maliyetleri ve özel ekipman gerekliliği gibi faktörler, uygulanabilirliğini etkileyebilir (Achouch vd., 2022). İşletmelerin spesifik ihtiyaçları ve kaynakları göz önünde bulundurularak, uygun bakım stratejisi seçilmelidir.



Şekil 16. Bakım Yöntemlerinin Maliyetleri

3.2.1. İnsansız Hava Araçlarında Kullanılan Veriler

Kestirimci bakım, endüstriyel ekipmanların sistematik bir şekilde izlenmesi ve analiz edilmesi yoluyla, arızaların önceden tespit edilmesini ve önlenmesini hedefleyen bir bakım stratejisidir (Ceyhan ve Kasapbaşı, 2022). Bu yaklaşım, ekipman verimliliğini artırarak duruş sürelerini azaltmak, bakım maliyetlerini düşürmek ve işletme sürekliliğini sağlamak gibi birçok avantaj sunar (Bulut, 2021).

Kestirimci bakımın temel özelliği, ekipmanlardan toplanan verilerin analizine dayanmasıdır. Bu veriler, ekipmanın çalışma koşullarını, performansını ve potansiyel arızalarını değerlendirmek amacıyla kullanılır. Kestirimci bakımın başarısı, doğru verilerin toplanmasına ve bu verilerin doğru şekilde analiz edilmesine bağlıdır (Van Dinter vd., 2022).


İHA'lerden elde edilen veriler, uçuş dinamiklerini, motor performansını, çevresel koşulları ve yapısal bileşenlerin durumunu analiz etmek için kullanılan sensörler, veri kaydediciler ve kontrol sistemleri aracılığıyla toplanmaktadır (Dong vd., 2014). Bu veriler, hava aracının mevcut sağlık durumunu değerlendirmek ve potansiyel riskleri önceden tahmin etmek için analiz edilir. Özellikle kestirimci bakım ve arıza tespiti süreçlerinde AI ve makine öğrenimi gibi ileri analitik yöntemler

kullanılarak, operasyonel süreklilik sağlanmakta ve bakım maliyetleri düşürülmektedir (Pawelczyk, 2021; Petritoli vd., 2018).

İHA sistemlerinde kullanılan veriler, uçuş dinamiklerinden motor performansına, yapısal sağlık izleme sistemlerinden çevresel faktörlere kadar geniş bir kategoride sınıflandırılmaktadır (Messaoudi vd., 2023). Bu verilerin doğru şekilde toplanması ve analiz edilmesi, hava aracının etkinliğini artırarak güvenli operasyonlar gerçekleştirilmesine katkı sağlamaktadır (Luo vd., 2017).

İHA’larda kullanılan veri toplama sistemleri, hava aracının uçuş karakteristiklerini, aerodinamik durumunu, motor ve enerji sistemlerinin performansını, çevresel değişkenleri ve yapısal bileşenlerin durumunu sürekli olarak izleyerek, güvenli uçuş gerçekleştirilmesini sağlamaktadır (Kopecki ve Rogalski, 2014; Ravi ve Arena, 2011; Abeywickrama vd., 2018). Veri toplama sürecinde ivmeölçerler, jiroskoplar, manyetometreler, GPS sistemleri, motor sıcaklık sensörleri, hava hızı sensörleri, titreşim algılayıcıları ve basınç sensörleri gibi çeşitli sensörler aktif olarak kullanılmaktadır (Wilson vd., 2021). Bu sensörlerden elde edilen veriler, uçuş kontrol sistemleri aracılığıyla işlenerek, anlık olarak değerlendirilmekte ve uçuş güvenliğini artıracak karar destek sistemlerine entegre edilmektedir (Samaras vd., 2019; Dudukcu vd., 2023).

Yaygın olarak kullanılan veri türleri arasında titreşim, yağ, kızılötesi, sıcaklık, ultrasonik ve duman verileri yer almaktadır. Bu veriler, ekipman arızalarının önceden tahmin edilmesi ve önlenmesi için önemli bir rol oynar bu şekil 17’de gösterilmiştir. (Perez, 2023; Song vd., 2022).



Şekil 17. Kestirimci Bakımda Kullanılan Veriler

İHA sistemlerinde titreşim analizi, hava aracının motorları, pervaneleri, gövde yapısı ve iniş takımlarındaki aşınma, mekanik gevşeme veya dengesizliklerin tespit edilmesi amacıyla kullanılmaktadır. Titreşim sensörleri, mekanik parçaların çalışma sırasında oluşturduğu titreşimleri ölçerek, sistemin genel sağlık durumu hakkında bilgi sağlamaktadır. Özellikle pervane balans bozuklukları, motor rulmanlarında aşınma ve yapısal bütünlük kayıpları titreşim analizi yoluyla tespit edilebilmektedir.

İHA’larda kullanılan motor türüne bağlı olarak yağ ve yakıt analizleri, sistemin genel sağlık durumunun izlenmesi açısından kritik bir rol oynamaktadır. Yağ verileri, kimyasal bileşimi ve fiziksel özellikleri analiz edilerek aşınma, korozyon, kirlenme ve su kontaminasyonu gibi unsurların tespit edilmesini sağlamaktadır. Yakıt analizi ise, yanma verimliliğini ve motorun optimum performansını değerlendirmek için kullanılmaktadır (Wang vd., 2019).

Sıcaklık sensörleri, motor, batarya, hava aracı gövdesi ve elektronik bileşenlerin aşırı ısınmasını veya soğuma durumlarını izlemek amacıyla kullanılmaktadır (Xu vd., 2022). İHA’ların operasyonel güvenliği açısından kritik bir parametre olan sıcaklık verileri, batarya yönetim sistemlerinde termal kaçakları tespit etmek ve motor sistemlerinde aşırı yüklenmeyi belirlemek için analiz edilmektedir (Greene vd., 2018; Du vd., 2023).

İHA sistemlerinde kullanılan kızılötesi sensörler, termal görüntüleme teknikleri ile motor, batarya, elektronik bileşenler ve yapısal bileşenlerde meydana gelen sıcaklık değişimlerini analiz etmek için kullanılmaktadır. Özellikle aşırı ısınma tespiti, elektriksel bağlantılarda direnç artışları ve motor sistemlerinde sıcaklık kaynaklı anormallikler, kızılötesi analizlerle belirlenerek erken uyarı mekanizmalarının devreye girmesi sağlanmaktadır (Aden vd., 2014; Jang ve Kim, 2008).

Ultrasonik sensörler, İHA bileşenlerinde yüzey çatlakları, hava kaçağı, gövde deformasyonları ve yüksek basınçlı sistemlerde meydana gelebilecek sızıntıların tespit edilmesini sağlamaktadır. Özellikle kompozit malzemelerden üretilen İHA gövdelerinde, yapısal bütünlük kayıpları ultrasonik testler aracılığıyla belirlenerek, bakım süreçleri optimize edilmektedir (Guerrero vd., 2015; Niwa vd., 2017).

İHA’ların çalışması sırasında ortaya çıkan motor gürültüleri ve akustik titreşimler, hava aracının mekanik ve elektriksel bileşenlerinde meydana gelen aşınmaların tespit edilmesi için analiz edilmektedir. Özellikle pervane ve motor bileşenlerindeki dengesizlikler, ses dalgalarının frekans analizi yoluyla tespit edilerek

kestirimci bakım süreçlerinde kullanılır (Sinibaldi, G., ve Marino, L. (2013; Mane vd., 2024).

İHA sistemlerinde kullanılan motorlar, yanma sonucu ortaya çıkan egzoz gazlarını belirli kimyasal bileşenlere ayırarak motorun performans analizini gerçekleştirmek için ölçülmektedir. Egzoz gazı analizi, motorun yanma verimliliğini, yakıt tüketimini ve çevresel etki parametrelerini belirleyerek sistemin çalışma performansını optimize etmeye yardımcı olmaktadır (Kucuk vd., 2024; Bahari vd., 2022).

3.2.2. Veriye Dayalı Kalan Faydalı Ömür Tahmini

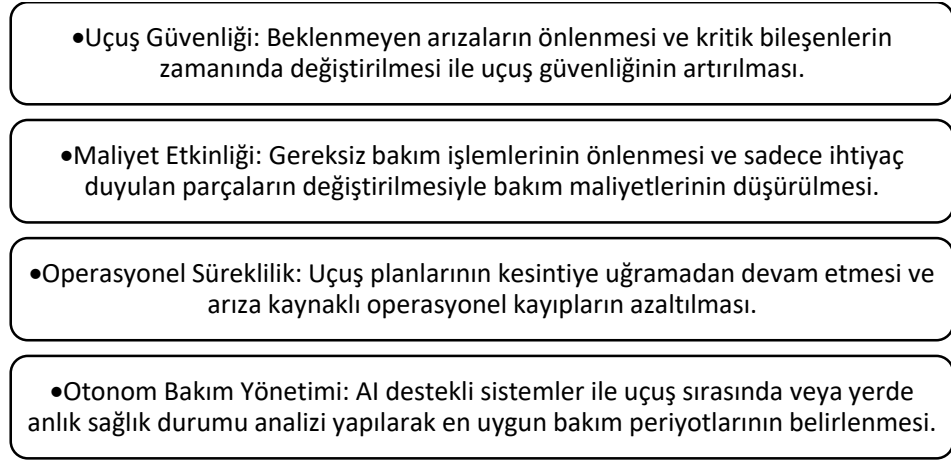
İHA askeri, endüstriyel ve ticari alanlarda geniş kullanım yelpazesine sahip, yüksek teknolojiye dayalı hava platformlarıdır. Bu sistemlerin operasyonel verimliliğinin ve güvenilirliğinin sağlanması, bakım süreçlerinin optimize edilmesi ve tahmini arıza yönetimi büyük önem taşımaktadır. Geleneksel bakım yöntemleri, genellikle belirli uçuş saatleri veya sabit periyotlarla uygulanırken, günümüz havacılık teknolojileri sensör verilerine dayalı kestirimci bakım yaklaşımlarını ön plana çıkarmaktadır (Korvesis, 2017). Bu yaklaşımlar içinde KFÖ tahmini, sistem bileşenlerinin ne zaman değiştirilmesi veya bakım gereksinimi duyacağını öngörmek amacıyla kritik bir yer tutmaktadır (Camci vd., 2021).

KFÖ, bir sistemin mevcut sağlık durumu ile kritik bir arızanın meydana geleceği zaman arasındaki süreyi ifade eden bir metriktir. Bu metrik, ML, DL ve sinyal işleme gibi veri analitiği teknikleri kullanılarak belirlenmektedir (Deutsch ve He, 2017; Ferreira ve Gonçalves, 2022). KFÖ tahmini, motor sistemleri, batarya ömrü, elektronik bileşenler, aerodinamik yapı ve mekanik parçalar gibi farklı İHA bileşenleri için ayrı ayrı hesaplanabilmektedir (Muhammad vd., 2021; Jiao vd., 2023). Tez kapsamında, sensör verileri ve uçuş geçmişi analiz edilerek, sistemde meydana gelebilecek arızaların önceden tahmin edilmesi ve bakım süreçlerinin optimize edilmesi amaçlanmaktadır.

KFÖ tahmini, geleneksel bakım yöntemlerine kıyasla daha esnek, maliyet etkin ve güvenilir bir bakım stratejisi sunmaktadır. Geleneksel yöntemler, planlı bakım uygulamalarına dayalı olduğu için, bileşenlerin gerçekte ne zaman arızalanacağı göz önüne alınmadan belirli zaman aralıklarında değişimi veya onarımı esas almaktadır. Ancak, KFÖ yaklaşımı, gerçek zamanlı sensör verileri ve geçmiş arıza kayıtları

üzerinden sistemin sağlık durumunu sürekli izleyerek en uygun bakım zamanlamasını belirlemektedir.

KFÖ tahmini, aşınma, yorgunluk, sıcaklık değişimleri, titreşim anomalileri ve elektriksel bozulmalar gibi sistemin çalışma süresi boyunca maruz kaldığı fiziksel ve çevresel faktörleri göz önüne alarak hesaplanmaktadır. Özellikle İHA motorları, pervane sistemleri, güç aktarım mekanizmaları ve batarya sistemleri gibi kritik bileşenler, zamanla yıpranarak performans kaybına uğramaktadır. KFÖ modeli, bu yıpranma sürecini öngörerek, beklenmedik arızaların önüne geçilmesini sağlamaktadır. KFÖ tahmini Şekil 18. 'da bulunan avantajları sağlamaktadır.



Şekil 18. Kalan Faydalı Ömür Tahmininin Avantajları

KFÖ tahmini, çeşitli matematiksel modelleme ve veri analitiği teknikleri ile gerçekleştirilmektedir. Günümüzde, en yaygın kullanılan yöntemler ML, DL modelleri ve istatistiksel analiz teknikleri ile desteklenmektedir.

İstatistiksel modelleme yöntemleri, KFÖ tahmini için en temel yöntemlerden biri, istatistiksel arıza dağılım fonksiyonları ve zaman serisi analizleridir. Bu yöntemde, geçmiş uçuş verileri analiz edilerek, belirli bileşenlerin arızalanma olasılığı tahmin edilmektedir.

Weibull Dağılımı Modeli, bir bileşenin aşınma sürecini ve arızalanma olasılığını belirlemek için yaygın olarak kullanılan bir modeldir. Markov Modelleri, bileşenlerin farklı sağlık durumları arasında geçiş olasılıklarını hesaplayarak KFÖ tahmini yapılmasını sağlar. Otomatik Regresyon Modelleri (ARIMA), zaman serisi analizleri ile sistemdeki aşınma eğilimlerini belirleyerek KFÖ süresini tahmin eder.

ML algoritmaları, büyük veri setlerinden örüntüleri öğrenerek sistemdeki potansiyel arızaları ve KFÖ süresini tahmin etmek için güçlü bir yöntem sunmaktadır. En yaygın kullanılan teknikler şunlardır;

SVM, sensör verileri ve geçmiş arıza kayıtlarını analiz ederek, bileşenlerin ne zaman arızalanabileceğini sınıflandırır. DT ve RF, KFÖ tahmini için kullanılan, veri setleri üzerinde etkili bir şekilde çalışabilen doğruluk oranı yüksek algoritmalar. ANN, büyük miktarda sensör verisini işleyerek karmaşık KFÖ tahmin modelleri oluşturur.

DL teknikleri, çok büyük veri setlerini işleyerek sistemde meydana gelebilecek arızaları yüksek doğruluk oranı ile tahmin etmek için kullanılmaktadır. Özellikle zaman serisi analizine dayalı RNN ve LSTM modelleri, İHA sistemlerinde KFÖ tahmininde en etkili yöntemler arasında yer almaktadır.

LSTM Modelleri, KFÖ hesaplamalarında geçmiş verileri kullanarak sistemin gelecekteki sağlık göstergelerini öngörmek için yaygın olarak kullanılmaktadır. Otoenkoder Ağları, Anomali tespiti yaparak bileşenlerin arızalanmadan önceki son dönemlerini analiz eder ve KFÖ tahmini için hassas modelleme yapar.

3.2.3. Veriye Dayalı Anomali Tespiti

İHA, yüksek manevra kabiliyeti, gelişmiş otonom uçuş yetenekleri ve farklı operasyonel senaryolara adaptasyonları sayesinde modern havacılık teknolojisinin en önemli bileşenlerinden biri haline gelmiştir. Bu sistemlerin güvenilirliği, uçuş güvenliği ve operasyonel sürekliliğin sağlanması açısından kritik öneme sahiptir. İHA'ların karmaşık dinamik yapısı, mekanik ve elektronik bileşenlerin sürekli olarak izlenmesini ve potansiyel anomalilerin tespit edilerek sistemin güvenli bir şekilde çalışmasını gerektirmektedir. Özellikle yüksek risk içeren askeri operasyonlar, sivil havacılık, arama kurtarma ve endüstriyel gözetleme gibi kritik görevlerde, sensör verilerine dayalı anomali algılama yöntemleri, İHA sistemlerinin güvenliğini sağlamak açısından büyük önem taşımaktadır.

İHA'lar, uçuş sırasında farklı fiziksel ve çevresel parametreleri sürekli olarak ölçen ve analiz eden çeşitli sensörlerle donatılmıştır. Bu sensörler; ivmeölçerler, jiroskoplar, manyetometreler, GPS sistemleri, hava hızı göstergeleri, motor sıcaklık sensörleri, batarya yönetim sistemleri ve aerodinamik basınç sensörleri gibi geniş bir yelpazeye yayılmaktadır. İHA'nın uçuş performansını ve çevresel değişkenleri sürekli

izleyen bu sistemler, olası bir arıza veya olağandışı bir durum meydana geldiğinde, uçuş güvenliğini sağlamak adına erken uyarı mekanizmalarının devreye girmesine olanak tanımaktadır. Sensör verilerine dayalı anomali algılama sistemleri, ML algoritmaları, büyük veri analitiği ve istatistiksel analiz yöntemleri ile birlikte çalışarak, normal çalışma koşullarından sapmaları tespit etmek ve olası arızaları önceden belirlemek için kullanılmaktadır.

Anomali algılama, bir sistemin beklenen veya normal çalışma koşullarından sapmalarını tespit etmek için kullanılan bir analiz yöntemidir. Bu yöntem, normal sistem davranışlarını temel alarak, beklenmeyen değişiklikleri ve sapmaları belirlemeye yönelik bir süreçtir. Anomali tespiti, özellikle karmaşık sistemlerde, geleneksel bakım yöntemlerinin yetersiz kaldığı durumlarda kritik bir öneme sahiptir. İHA sistemlerinde sensör verilerine dayalı anomali algılama, uçuş sırasında meydana gelebilecek arızaların erken teşhisi, uçuş güvenliğinin sağlanması ve bakım süreçlerinin optimize edilmesi açısından büyük bir avantaj sunmaktadır.

Anomali algılama yöntemleri, genellikle geçmiş verilerle karşılaştırmalı analiz yaparak, sistemde meydana gelen olağandışı değişimleri belirlemeye yönelik çalışmaktadır. İHA'ların sensörlerinden elde edilen veriler, belirli bir eşik değerin üzerine çıktığında veya belirli bir frekansta anormal bir değişiklik gösterdiğinde, sistemin beklenmeyen bir duruma girdiği tespit edilir. Örneğin, motor sıcaklığının normal çalışma aralığının üzerine çıkması, kanat titreşimlerinin beklenenden daha yüksek seviyeye ulaşması veya batarya voltaj seviyelerinde düzensizlikler gözlemlenmesi gibi durumlar, anomali tespit sistemleri tarafından olası bir arızanın habercisi olarak değerlendirilmektedir.

İHA sistemlerinde sensör verilerine dayalı anomali algılama, farklı teknikler ve algoritmalar aracılığıyla gerçekleştirilmektedir. Bu yöntemler, istatistiksel analizler, ML teknikleri, denetimli ve denetimsiz öğrenme modelleri ile zaman serisi analizlerini içermektedir.

İstatistiksel yöntemler, sensör verilerinin belirli bir dağılım modeline dayalı olarak analiz edilmesine dayanır. Bu yöntemler, belirli bir sensör verisinin normal dağılımını belirleyerek, bu dağılımdan sapmaları anomali olarak işaretler. Örneğin, bir İHA'nın motor sıcaklığı, normal çalışma koşullarında belirli bir aralıkta değişiklik gösterirken, anormal bir artış veya azalış durumunda sistemde bir arıza meydana gelme

olasılığı yüksektir. Bu tür durumlar, z-score analizi, Gaussian dağılımı ve hipotez testleri gibi yöntemler kullanılarak tespit edilebilir.

ML, büyük veri setleri üzerinde anormal örüntüleri belirlemek için kullanılan en etkili yöntemlerden biridir. Denetimli ve denetimsiz öğrenme modelleri, İHA'lerden gelen sensör verilerini analiz ederek, normal ve anormal durumları otomatik olarak sınıflandırabilmektedir.

Denetimli öğrenme yöntemleri, etiketlenmiş veri setleri kullanarak anomaliyi tespit eder. Örneğin, geçmiş uçuş verilerinde meydana gelen arızaların etiketlenmesiyle eğitilen bir model, yeni veriler üzerinde benzer anomalileri tespit edebilir.

Denetimsiz öğrenme yöntemleri ise belirli bir eğitim sürecine ihtiyaç duymadan, sensör verilerindeki olağandışı desenleri tespit edebilir. Özellikle Kümeleme (clustering), Principal Component Analysis (PCA) ve Otoenkoder gibi yöntemler, sensör verilerinin normal dağılımını belirleyerek, bu dağılımdan sapmaları anomali olarak işaretleyebilir. ML destekli sistemlerin avantajı, insan müdahalesine gerek duymadan büyük veri setleri üzerinden sürekli öğrenme sağlayarak anomali tespitinde yüksek doğruluk oranı sunmasıdır.

3.3. Arıza Tespitinde Yapay Zeka Kullanımı

AI kavramı Tablo 3. gösterildiği üzere ilk olarak 1950 yılında Alan Turing tarafından ortaya atılmıştır. Turing, makinelerin insan gibi düşünme yeteneğine sahip olup olmadığını değerlendirmek için Turing Testi'ni önererek AI çalışmalarının temelini atmıştır. 1956 yılında John McCarthy, Dartmouth Konferansı'nda "AI" terimini kullanarak bu alanın resmi olarak bir araştırma disiplini haline gelmesini sağlamıştır. 1965 yılında Lotfi Zadeh, Bulanık Mantık (Fuzzy Logic) kavramını geliştirerek AI'nın belirsiz ve bulanık verilerle çalışabilmesine olanak tanımıştır. 1974 yılında Paul Werbos, sinir ağlarının eğitimi için kritik bir teknik olan Geri Yayılım (Backpropagation) algoritmasını tanıtarak ANN daha verimli bir şekilde öğrenmesini mümkün kılmıştır. 1980 yılında Teuvo Kohonen, Kendi Kendini Organize Eden Harita (Self-Organizing Map, SOM) yöntemini geliştirerek sinir ağlarının kendiliğinden öğrenmesini sağlayan yeni bir yaklaşım sunmuştur. 1982'de John Hopfield, Hopfield Ağı adı verilen modeli geliştirerek ANN farklı kullanım alanlarını genişletmiştir.

Tablo 3. Yapay Zekanın Tarihsel Süreçleri

Yıl	Kişi	Sağlanan Katkı
1950	Alan Turing	Turing Testi'ni önererek AI kavramını ortaya attı.
1956	John McCarthy	Dartmouth Konferansı'nda "AI" terimini ortaya attı.
1965	Lotfi Zadeh	Bulanık Mantık (Fuzzy Logic) kavramını geliştirdi.
1974	Paul Werbos	Geri Yayılım (Backpropagation) algoritmasını tanıttı.
1980	Teuvo Kohonen	SOM yöntemini geliştirdi.
1982	John Hopfield	Hopfield Ağı'nı tanıttı ve nöral ağlar için yeni bir model sundu.
1985	David Rumelhart ve James McClelland	Paralel Dağıtık İşleme (PDP) modelini önererek sinir ağlarının gelişmesine katkı sağladı.
1989	Yann LeCun	İlk DL modelini geliştirerek LeNet-5'i sundu.
1997	Hochreiter ve Schmidhuber	LSTM algoritmasını geliştirerek RNN'lerde kaybolan gradyan sorununu çözdü.
2006	Geoffrey Hinton	Derin inanç ağlarını (Deep Belief Networks-DBN) tanıttı ve DL çağını başlattı.
2009	Andrew Ng ve Fei-Fei Li	Büyük veri setleri ve grafik işlemci birimi (Graphics Processing Unit-GPU) kullanımıyla DL nin hızla gelişmesini sağladı.
2012	Geoffrey Hinton	Dropout yöntemini tanıtarak sinir ağlarının daha verimli eğitilmesini sağladı.
2015	Yann LeCun ve Bengio ve Hinton	DL nin birçok alanda devrim niteliğinde bir ilerleme kaydetmesini sağladı.
2016	AlphaGo (DeepMind)	AI'nın insan şampiyonu Go oyununda yenmesiyle büyük bir ilerleme sağladı.
2020	OpenAI	GPT-3 modelini geliştirerek doğal dil işleme alanında büyük bir devrim gerçekleştirdi.

1985 yılında David Rumelhart ve James McClelland, PDP modelini tanıtarak sinir ağlarının biyolojik beyin modellerine daha uygun hale gelmesini sağlamışlardır. 1989'da Yann LeCun, LeNet-5 adlı ilk DL modelini tanıtarak ANN görüntü işleme alanında kullanılmasını sağlamıştır. 1997 yılında Hochreiter ve Schmidhuber, LSTM algoritmasını geliştirerek RNN için büyük bir problem olan kaybolan gradyan sorununu (vanishing gradient problem) çözmüşlerdir.

2006 yılında Geoffrey Hinton, DBN modelini tanıtarak DL çağını başlatmıştır. 2009 yılında Andrew Ng ve Fei-Fei Li, büyük veri setleri ve GPU kullanımıyla DL modellerinin çok daha verimli hale gelmesini sağlamışlardır. 2012 yılında Geoffrey Hinton, sinir ağlarının daha verimli eğitilmesini sağlayan Dropout yöntemini geliştirerek AI'nın eğitim sürecine büyük katkı sunmuştur. 2015 yılında Yann LeCun, Bengio ve Hinton, DL'nin birçok alanda devrim niteliğinde bir ilerleme kaydetmesini

sağlayarak bu alandaki çalışmalara büyük katkıda bulunmuşlardır. 2016 yılında, Google DeepMind tarafından geliştirilen AlphaGo, dünyaca ünlü Go şampiyonlarını yenerek AI'nın karar verme yeteneklerinde ne kadar ileri gidebildiğini göstermiştir. 2020 yılında ise OpenAI, GPT-3 modelini geliştirerek doğal dil işleme alanında büyük bir devrim gerçekleştirmiştir.

Bu gelişmeler, AI tabanlı kestirimci bakım sistemlerinin gelişmesine de büyük katkı sağlamıştır. İHA, modern havacılık, savunma, lojistik, tarım, sanayi ve diğer birçok alanda giderek daha yaygın bir şekilde kullanılmaktadır. Gelişen teknoloji ile birlikte İHA sistemlerinin yalnızca uçuş performansını artırmak değil, aynı zamanda bakım süreçlerini optimize ederek operasyonel sürekliliği sağlamak da kritik bir mühendislik gereksinimi haline gelmiştir. Bu bağlamda, İHA'ların güvenilirliğinin artırılması, beklenmedik arızaların önüne geçilmesi ve bakım süreçlerinin verimli hale getirilmesi için gelişmiş arıza tespit yöntemlerine ihtiyaç duyulmaktadır.

Geleneksel arıza tespit yöntemleri, genellikle reaktif bakım veya önleyici bakım stratejilerine dayanmaktadır. Reaktif bakım, bir sistem arızalandıktan sonra yapılan müdahaleleri kapsarken, önleyici bakım ise belirli zaman dilimlerinde veya uçuş saatleri baz alınarak yapılan planlı bakımları ifade etmektedir. Ancak, bu yöntemler çoğu zaman sistemde gereksiz bakım işlemlerine neden olmakta ya da bazı durumlarda beklenmedik arızaları önleyememektedir. Bu nedenle, son yıllarda kestirimci bakım (predictive maintenance) yaklaşımı ön plana çıkmış ve AI tabanlı arıza tespit sistemleri geliştirilmiştir.

AI, büyük veri analizi, otomatik karar mekanizmaları, anomali tespiti ve karmaşık örüntülerin belirlenmesi gibi yetenekleri sayesinde, İHA sistemlerinde arıza tespiti ve bakım süreçlerinin optimizasyonu için güçlü bir araç olarak öne çıkmaktadır. Geleneksel yöntemler belirli kurallar çerçevesinde manuel analizlere dayanırken, AI sistemleri büyük miktarda veriyi analiz ederek insan müdahalesine gerek duymadan sistemde oluşabilecek anomalileri tespit edebilir.

İHA'larda AI tabanlı arıza tespit sistemleri, bileşenlerden elde edilen sensör verilerini analiz ederek, sistemin genel sağlık durumunu sürekli izlemekte ve arızaların erken tespit edilmesini sağlamaktadır. Bu sistemler, ML, sinyal işleme ve DL gibi alt disiplinler aracılığıyla çalışarak İHA'ların güvenli ve uzun ömürlü bir şekilde operasyonlarını sürdürebilmesine olanak tanımaktadır.

AI destekli arıza tespit sistemleri, sensörlerden gelen büyük veri setlerini analiz ederek anomali ve KFÖ tespiti yapmakta, sistemin gelecekteki çalışma durumunu tahmin etmektedir. Bu sistemler, motor sıcaklığı, titreşim seviyeleri, batarya durumu, elektrik akımı, hava akımı, kanat yükleri ve diğer önemli parametreleri sürekli izleyerek, beklenmedik bir arızanın meydana gelmeden önce önlem alınmasını sağlamaktadır. Veri işleme süreci genellikle üç aşamada gerçekleşir:

(i) Veri Toplama ve Ön İşleme

İHA üzerindeki sensörlerden anlık veya periyodik olarak veri toplanır. Gürültü filtreleme, eksik veri tamamlama ve özellik mühendisliği teknikleri ile ham veriler işlenir.

(ii) Özellik Çıkartma ve Model Eğitimi

İHA sistemlerinin farklı çalışma koşulları için normal operasyon verileri belirlenir. Anomali ve KFÖ tespiti ve hata sınıflandırması için ML algoritmaları eğitilir.

(iii) Gerçek Zamanlı Arıza Tespiti ve Tahmini Bakım


Eğitilmiş model, anlık sensör verilerini analiz ederek sistemin sağlığını değerlendirir. Olası arızalar önceden tahmin edilerek bakım süreçleri optimize edilir.

ML, İHA'ların arıza tespit süreçlerinde kullanılan en yaygın ve etkili AI tekniklerinden biridir. Geleneksel bakım ve arıza tespit yöntemleri, genellikle operatörlerin tecrübelerine ve belirli aralıklarla yapılan periyodik kontrollerin sonuçlarına dayanmaktadır. Ancak bu yaklaşım, birçok durumda gecikmelere, operasyonel verimsizliğe ve gereksiz maliyetlere neden olabilmektedir. İHA'ların karmaşık sistemlere sahip olması ve sürekli değişen çevresel koşullara maruz kalması nedeniyle, bu geleneksel yöntemler yetersiz kalabilmektedir. Bu noktada, ML tabanlı sistemler, büyük hacimli verileri analiz ederek hem geçmişe dayalı öğrenme sağlar hem de anlık ve geleceğe yönelik tahminler yapabilir.

ML yöntemleri, veri türlerine ve uygulama senaryolarına bağlı olarak denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve takviyeli öğrenme (reinforcement learning) gibi farklı kategorilere ayrılmaktadır. Her bir yöntem, farklı problem türlerine uygun şekilde uygulanarak arıza tespit sürecini daha verimli ve etkili hale getirmektedir.

Denetimli öğrenme, modelin belirli bir eğitim sürecinden geçerek öğrenmesini sağlayan bir yaklaşımdır. Bu yöntemde, sistemin normal çalışma koşulları ile arızalı


durumları tanımlayan etiketlenmiş (labeled) bir veri kümesi kullanılır. Model, geçmişte toplanan bu veriler üzerinden eğitilir ve gelecekteki yeni verileri sınıflandırarak potansiyel arızaları veya anormallikleri tespit eder. Denetimli öğrenme yöntemleri, genellikle aşağıdaki algoritmalarla uygulanır. (Şekil 19)



Şekil 19. Denetimli Öğrenme Yöntemleri

Denetimli öğrenmenin en büyük avantajı, etiketlenmiş veri ile yüksek doğruluk oranına sahip modeller üretebilmesidir. Ancak bu yöntem için önceden etiketlenmiş büyük miktarda veri gerekliliği, önemli bir kısıtlayıcı faktör olabilir. Etiketleme süreci zaman alıcı ve maliyetli olabileceğinden, bazı durumlarda denetimsiz öğrenme yöntemlerine başvurulmaktadır.

Denetimsiz öğrenme, modelin herhangi bir etiketli veri olmadan anormallikleri veya sistemdeki bilinmeyen kalıpları keşfetmesini sağlayan bir yöntemdir. Bu teknik, özellikle İHA'larda bilinmeyen arıza türlerini tespit etmek veya farklı operasyonel koşullara göre değişen davranışları analiz etmek için kullanılır. Denetimsiz öğrenme yöntemleri arasında en yaygın kullanılanlar şunlardır. (Şekil 20)



Şekil 20. Denetimsiz Öğrenme Yöntemleri

Denetimsiz öğrenmenin avantajı, modelin önceden belirlenmiş arıza türlerine bağımlı olmadan yeni tür anomalileri keşfetmesidir. Ancak bu tekniklerin dezavantajı, bazen yanlış pozitif (false positive) sonuçların fazla olması ve yorumlamanın zor olabilmesidir.

Takviyeli öğrenme (Reinforcement Learning - RL), bir sistemin belirli bir hedefe ulaşması için çevresinden gelen geri bildirimlerle kendi kendine öğrenmesini sağlayan bir yöntemdir. İHA'ların bakım ve arıza yönetiminde optimum kararlar almasını sağlayacak şekilde kullanılabilir.

- Q-Öğrenme (Q-Learning) ve Derin Takviyeli Öğrenme (Deep Reinforcement Learning - DRL) gibi yöntemler, bakım kararlarının dinamik olarak optimize edilmesine yardımcı olur.

- RL tabanlı sistemler, İHA'nın operasyon süresince karşılaştığı anormal durumlara göre bakım önceliklerini belirler.
- Örnek: Bir İHA, belirli bir görev sırasında motor sıcaklığında anormal bir artış tespit ederse, RL tabanlı sistem en uygun bakım senaryosunu oluşturabilir ve kritik bileşenlerin değiştirilmesini önerir.

Takviyeli öğrenmenin en büyük avantajı, sistemin değişen çevresel koşullara uyum sağlayarak kararlarını sürekli olarak geliştirebilmesidir. Ancak bu teknik, yüksek hesaplama gücü gerektirmesi, işlem limitinin yüksek olması ve optimum politika belirlenimin zaman alıcı olması gibi dezavantajlara da sahiptir.

3.3.1. Sinyal İşleme

İHA, havacılık ve savunma sanayisinden tarım ve lojistiğe kadar geniş bir kullanım alanına sahip olup, operasyonel güvenilirlikleri açısından gelişmiş analiz yöntemlerine ihtiyaç duymaktadır. Bu doğrultuda, İHA sistemlerinde kullanılan sensörler aracılığıyla sürekli olarak veri toplanmakta ve bu verilerin işlenerek anlamlı bilgiler haline getirilmesi gerekmektedir. Sensörlerden elde edilen verilerin işlenmesi süreci, sinyal işleme olarak adlandırılmakta olup, bu yöntem sayesinde İHA'nın sistem durumu izlenebilmekte, anormallikler tespit edilebilmekte ve önleyici bakım süreçleri planlanabilmektedir.

Sinyal işleme, İHA'larda motor titreşimleri, hava akışı değişiklikleri, batarya durumu, pervane dengesizliği, aerodinamik veriler ve elektronik bileşenlerin çalışma koşulları gibi birçok farklı faktörü analiz edebilme kapasitesine sahiptir. Sistemden alınan ham verilerin doğrudan analiz edilmesi genellikle zordur çünkü bu veriler çeşitli gürültüler, parazitler veya sistem içi değişkenlerden etkilenerek doğru sonuçlar vermeyebilir. Bu nedenle sinyal işleme, ham verinin filtrelenmesi, ayrıştırılması ve dönüştürülmesi gibi işlemleri içererek daha anlamlı hale getirilmesini sağlar.

İHA'larda sinyal işleme süreci, genellikle zaman alanı (time domain), frekans alanı (frequency domain) ve zaman-frekans alanı (time-frequency domain) analizleriyle gerçekleştirilir. Zaman alanı analizleri, sistemin belirli bir zaman diliminde nasıl değiştiğini gösterirken, frekans alanı analizleri ise sistemde meydana gelen düzensizliklerin hangi frekansta gerçekleştiğini ortaya koyarak daha hassas arıza tespitine olanak tanır. Bununla birlikte, zaman-frekans alanı analizi, sinyalin hem

zamansal hem de frekans bileşenlerini aynı anda inceleyerek, özellikle zamana bağlı değişkenlik gösteren sinyallerin daha ayrıntılı analiz edilmesini sağlar.

Bu bağlamda, Fourier Dönüşümü (Fourier Transform-FT) ve Hızlı Fourier Dönüşümü (Fast Fourier Transform-FFT) frekans alanı analizinde yaygın olarak kullanılırken, Dalga Dönüşümü (Wavelet Transform-WT) ve Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform-STFT) gibi teknikler zaman-frekans alanı analizleri için tercih edilmektedir. Özellikle WT, sinyalin hem düşük hem de yüksek frekans bileşenlerini belirli zaman aralıklarında inceleyerek arıza tespitinde büyük avantaj sağlar. Bu tekniklerin kullanımı, İHA'lardan gelen verilerin daha etkin bir şekilde analiz edilmesine ve erken uyarı sistemlerinin geliştirilmesine katkı sağlamaktadır.

Zaman alan analizi, titreşim ölçümlerine dayalı kestirimci bakım, İHA mekanik bileşenlerinde oluşabilecek arızaların erken tespit edilmesi ve önleyici bakım stratejilerinin uygulanması açısından kritik bir öneme sahiptir. Bu bağlamda zaman alan analizi, titreşim sinyallerinin zaman içindeki değişimini inceleyerek sistemin sağlığı hakkında önemli bilgiler sunan bir yöntemdir. Titreşim sinyallerinin genliği, frekansı ve fazı gibi temel bileşenleri dikkate alınarak yapılan analizler, meydana gelebilecek yapısal ve mekanik arızaların önceden belirlenmesine olanak tanır (Ceryan vd., 2021; Koca ve Ünsal, 2017; Samuel ve Pines, 2005).

İHA'lar, özellikle motor, pervane, gövde ve aktarma organları gibi sürekli dinamik yük altında çalışan bileşenlere sahiptir. Bu bileşenlerde oluşabilecek arızalar, sistemin genel performansını olumsuz etkileyebileceği gibi, hava aracı için kritik güvenlik riskleri de oluşturabilir. Geleneksel bakım yöntemleri genellikle belirli zaman aralıklarında yapılan kontrollerle sınırlıdır ve potansiyel arızalar gözden kaçabilir. Ancak, titreşime dayalı kestirimci bakım sistemleri, sürekli veri akışı sağlayarak erken teşhis imkanı sunar ve beklenmedik arızaların önüne geçerek bakım maliyetlerini azaltır (Ceryan vd., 2021).

Zaman alan analizi, İHA üzerindeki çeşitli sensörlerden toplanan titreşim sinyallerinin zamana bağlı değişimini gösteren grafikler oluşturur. Bu grafiklerde, sinyalin genliği zamana karşı çizilerek sistemin çalışma dinamikleri görselleştirilir. Titreşim verileri, belirli bir örnekleme frekansında kaydedilir ve analiz edilir. Örnekleme frekansı, sistemin en yüksek frekans bileşeninin en az iki katı olacak şekilde belirlenmelidir. Bu, Nyquist Örnekleme Teoremi'ne uygun olarak, sinyaldeki

bilgi kaybının önüne geçilmesini sağlar. Düşük örnekleme frekansları, önemli frekans bileşenlerinin kaybolmasına ve hatalı analizlere neden olabilir (Koca ve Ünsal, 2017).

İHA'ların titreşim verileri üzerinde yapılan zaman alan analizleri, belirli istatistiksel metriklerin hesaplanmasını gerektirir. Bu metrikler, titreşim sinyalinin karakteristik özelliklerini belirlemek ve olası arızaları tespit etmek için kritik öneme sahiptir. Titreşim analizi bazlı kestirimci bakım sistemlerinde kullanılan temel zaman alanı metrikleri şunlardır;

- Ortalama (μ) : Titreşim sinyalinin ortalama genliğini ifade eder. Genellikle istikrarlı bir sistemde sıfıra yakın değerler alması beklenir.
- Standart Sapma (σ): Titreşim sinyalinin genliğinde zaman içindeki değişkenliği gösterir. Yüksek standart sapma, sistemde düzensiz hareketlerin veya ani yük değişimlerinin bulunduğunu gösterebilir.
- Kök Ortalama Kare (Root Mean Square-RMS): Sinyalin enerjisini temsil eden bir ölçümdür. Titreşim büyüklüğünü anlamak için yaygın olarak kullanılır.
- Pik-Pik Değeri (P_p): Sinyalin en yüksek ($\max(x)$) ve en düşük ($\min(x)$) değerleri arasındaki farktır. Bu değer, anlık darbeleri veya ani şokları belirlemek için kullanılır.
- Kurtosis Katsayısı (KR): Sinyalin istatistiksel dağılımının sivrililiğini (kuyrukluğunu) gösterir. Yüksek kurtosis değeri, ani darbe veya şokların sistemde sıkça meydana geldiğini gösterir.
- Crest Faktörü (F_c): Titreşim sinyalinin pik değeri ile RMS değeri arasındaki oranı ifade eder. Arızaların tespitinde önemli bir göstergedir, çünkü yüksek crest faktörü mekanik problemlerin göstergesi olabilir (Samuel ve Pines, 2005).

Bu metriklerin matematiksel ifadeleri Denklemler 1 – 6 arasında gösterilmiştir. Bu ifadeler, titreşim sinyalinin farklı yönlerini analiz ederek mekanik arızaların ve performans kayıplarının tespit edilmesine yardımcı olur.

$$\mu = \frac{1}{T} \int_0^T x(t) dt \quad (1)$$

$$\sigma = \sqrt{\frac{1}{T} \sum_{t=1}^T (x(t) - \bar{x})^2} \quad (2)$$

$$RMS = \frac{1}{T} \int_{-\infty}^{\infty} x^2(t) dt \quad (3)$$

$$P_p = \max(x(t)) - \min(x(t)) \quad (4)$$

$$KR = \frac{\int_{-\infty}^{\infty} (x(t) - \bar{x})^4 dt}{RMS^4} \quad (5)$$

$$F_c = \frac{P_p}{RMS} \quad (6)$$

İHA'ların operasyonları sırasında motorlarda, pervanelerde veya gövdede oluşabilecek aşınmalar, gevşemeler veya balanssızlıklar zaman içinde titreşim seviyelerinde değişimlere yol açar. Örneğin, bir motor rulmanında aşınma meydana geldiğinde, RMS değeri kademeli olarak artarken, kurtosis değeri de ani değişikliklere uğrayabilir. Benzer şekilde, pervane balanssızlığı durumunda, pik-pik değerinde artışlar gözlemlenebilir ve sinyalin frekans bileşenleri arasında belirgin değişimler ortaya çıkabilir (Koca ve Ünsal, 2017).

Titreşim verilerinin zaman alan analizine dayalı olarak değerlendirilmesi, arızaların erken teşhisi ve önleyici bakım planlarının oluşturulması açısından büyük bir avantaj sağlar. Özellikle İHA'larda sürekli titreşim ölçümleri yapılarak normal çalışma koşullarıyla kıyaslamalar yapılabilir ve anormal değişimler algılanarak arıza riski taşıyan bileşenler belirlenebilir. Geleneksel bakım yöntemlerinde belirli aralıklarla yapılan kontroller, beklenmeyen arızaların önüne geçmekte yetersiz kalabilirken, zaman alan analizine dayalı kestirimci bakım sistemleri, anlık veri analizi sayesinde planlı ve etkili bir bakım yönetimi sunmaktadır (Ceryan vd., 2021).

Sonuç olarak, zaman alan analizi, İHA'ların operasyonel güvenilirliğini artırmak, bakım süreçlerini optimize etmek ve beklenmeyen arızaların önüne geçmek için kritik bir rol oynar. Titreşim ölçümlerine dayalı kestirimci bakım, özellikle hava araçlarının uzun vadeli performansını artırmak ve güvenlik standartlarını yükseltmek açısından

büyük bir potansiyele sahiptir. Gelecekte, AI ve ML algoritmalarının zaman alan analizi ile entegre edilmesiyle, İHA'ların bakım yönetimi daha da akıllı hale gelecek ve tamamen otonom kestirimci bakım sistemleri geliştirilecektir. Bu gelişmeler, İHA'ların bakım maliyetlerini azaltırken, operasyonel verimliliği de artıracaktır (Samuel ve Pines, 2005; Koca ve Ünsal, 2017; Ceryan vd., 2021).

Frekans alan analizi, titreşim ölçümlerine dayalı kestirimci bakım, İHA operasyonel güvenilirliğini sağlamak ve beklenmeyen arızaların önüne geçmek için kritik bir yöntemdir. Frekans alan analizi, titreşim verilerini frekans bileşenlerine ayırarak, sistemin farklı bileşenlerinde meydana gelebilecek arızaları belirlemeye yardımcı olur. Bu yöntem, titreşim sinyallerinin zamana bağlı analiz edilmesinin yanı sıra, frekans bileşenlerine ayrılmasıyla spesifik mekanik hataların tespit edilmesini sağlar (Ceryan vd., 2021; Koca ve Ünsal, 2017; Samuel ve Pines, 2005).

İHA'lar, dinamik yükler altında çalışan karmaşık mekanik sistemlerdir. Özellikle motorlar, pervaneler, aktarma organları ve gövde üzerindeki çeşitli bileşenler, uzun süreli kullanımlarda aşınmaya, dengesizliğe veya gevşemeye maruz kalabilir. Bu tür mekanik kusurlar, belirli frekans aralıklarında anormal titreşim bileşenleri üreterek arızaların erken tespit edilmesini mümkün kılar. Geleneksel zaman alan analizleri bu anomalilerin kaynağını belirlemede yetersiz kalabilirken, frekans alan analizi, her bir bileşenin ürettiği titreşimlerin detaylı bir şekilde incelenmesine olanak tanır (Samuel ve Pines, 2005).

Frekans alan analizi, FFT gibi matematiksel teknikler kullanılarak gerçekleştirilir. Bu dönüşümler, zamana bağlı olarak değişen titreşim sinyallerini farklı frekans bileşenlerine ayırarak, sistemin çalışma karakteristiği hakkında daha kapsamlı bilgiler sunar. FFT sayesinde, titreşimin hangi frekansta yoğunlaştığı, belirli frekanslarda olağan dışı artış olup olmadığı ve sistemin hangi bileşeninde potansiyel bir arıza olduğu tespit edilebilir (Ceryan vd., 2021).

Frekans alan analizinde kullanılan temel araçlardan biri güç spektrumu grafiğidir. Bu grafik, frekansın bir fonksiyonu olarak titreşim seviyesini gösterir ve belirli frekans bileşenlerinin güç yoğunluğunu analiz etmeye olanak tanır. Grafikte yer alan zirve noktaları, sistemin belirli bir parçasındaki titreşim yoğunluğunu temsil eder ve anormal bir artış, potansiyel bir mekanik sorunun habercisi olabilir. Örneğin, bir motor rulmanında oluşan bir hasar, belirli bir frekansta titreşim üretir ve bu bileşen, güç

spektrumu grafiğinde belirgin bir tepe noktası olarak gözlemlenir (Koca ve Ünsal, 2017).

Zaman-frekans alan analizi, titreşim ölçümlerine dayalı kestirimci bakım teknikleri, makinelerin ve mekanik sistemlerin sağlık durumunu izlemek ve olası arızaları önceden tespit etmek için yaygın olarak kullanılan yöntemlerdir. Zaman-frekans alan analizi, bu süreçte kritik bir rol oynayarak, titreşim sinyallerinin hem zaman hem de frekans bileşenleri üzerinden detaylı bir değerlendirme yapılmasını sağlar. Geleneksel zaman alanı ve frekans alanı analizlerinin birleşimi olan bu yöntem, özellikle değişken çalışma koşullarına sahip sistemlerde ve geçici (transient) sinyallerin incelenmesinde büyük avantajlar sunar. İHA sistemlerinde, pervane dengesizliği, motor hataları, bağlantı gevşemeleri ve gövde rezonans problemleri gibi birçok mekanik arıza zaman-frekans analiziyle erken aşamada tespit edilebilir.

Zaman-frekans analizi, titreşim sinyallerinin zamana bağlı olarak frekans içeriğinin nasıl değiştiğini inceleyerek, belirli bir arızanın kaynağına ilişkin daha kesin bilgiler sunar. Zaman alanında belirli bir anomali tespit edildiğinde, bu anomalinin hangi frekans bileşenlerinden kaynaklandığını anlamak için frekans analizi kullanılır. Ancak, sistemler zamanla değişen dinamiklere sahip olduğunda, yalnızca zaman veya yalnızca frekans analizleri tek başına yeterli olmayabilir. İşte bu noktada, zaman-frekans alan analizi, hem zaman hem de frekans bileşenlerinin aynı anda incelenmesine olanak tanır, böylece sistemde meydana gelen geçici değişimlerin kaynağı daha net bir şekilde belirlenebilir (Ceryan vd., 2021; Koca ve Ünsal, 2017; Samuel ve Pines, 2005). Zaman-frekans analizinde kullanılan matematiksel yöntemler, titreşim sinyallerinin farklı yönlerini anlamaya yardımcı olur. Bu yöntemlerden bazıları sırasıyla;

- WT
- Gabor Dönüşümü
- Wigner-Ville Dağılımı (Wigner-Ville Distribution - WVD)
- Spektrogram (STFT)
- Çözünürlük Spektrumu
- Çapraz Spektrum Analizi

Bu yöntemler arasında wavelet dönüşümü, zaman-frekans analizi için en yaygın kullanılan tekniklerden biridir. Wavelet dönüşümü, bir sinyalin hem zaman hem de frekans bileşenlerine ayrıştırılmasını sağlayarak, farklı zaman ölçeklerinde meydana gelen frekans değişimlerini analiz etmeye olanak tanır.

Zaman-frekans analizinin İHA sistemlerinde kullanımı, diğer geleneksel analiz yöntemlerine göre birçok avantaja sahiptir;

(i) Değişken frekans bileşenlerini takip etme, İHA’larda, titreşim kaynakları zaman içinde değişebilir. Geleneksel frekans analizleri bu değişimleri yeterince iyi gösteremezken, zaman-frekans analizi anlık değişimleri detaylı bir şekilde gözlemlemeye olanak tanır.

(ii) Geçici arızaları tespit etme, bazı mekanik arızalar sürekli olmayıp belirli zaman dilimlerinde meydana gelir. Örneğin, motorda periyodik olmayan bir sürtünme veya pervane balanssızlığı zaman zaman ortaya çıkabilir. Bu tür geçici anomaliler, wavelet dönüşümü ve spektrogram ile daha kolay tespit edilir.

(iii) Titreşim kaynağının belirlenmesi, zaman alanı veya frekans alanı analizleri tek başına titreşimin hangi bileşenden kaynaklandığını tam olarak belirleyemezken, zaman-frekans analizi arızanın kaynağına dair daha net bir değerlendirme yapılmasını sağlar.

(iiii) AI destekli analizlerle entegrasyon, ML ve AI teknikleri ile entegre edildiğinde, zaman-frekans analizi otomatik arıza tespit sistemlerinde güçlü bir veri kaynağı oluşturur.

3.3.2. Derin Öğrenme

Günümüzde İHA, otonom uçuş yetenekleri, veri toplama kapasitesi ve yüksek hassasiyet gerektiren görevlerdeki kullanımları sayesinde giderek daha yaygın hale gelmektedir. İHA’ların operasyonel verimliliğini artırmak, arıza tahmini yapmak, nesne tanıma sistemlerini iyileştirmek ve kestirimci bakım süreçlerini optimize etmek amacıyla DL tekniklerinden yararlanılmaktadır. DL, özellikle büyük veri setleriyle çalışabilmesi ve karmaşık ilişkileri öğrenerek geleceğe yönelik tahminlerde bulunabilmesi sayesinde İHA sistemlerinde karar verme süreçlerini geliştiren güçlü bir araç haline gelmiştir.

DL, ANN temelinde geliştirilen ve çok katmanlı veri işleme mimarilerine dayanan bir ML yaklaşımıdır. Geleneksel ML yöntemlerinden farklı olarak, özellik

mühendisliğine ihtiyaç duymadan verilerden otomatik olarak anlamlı örüntüler çıkartabilme yeteneğine sahiptir. Bu durum, İHA sistemleri gibi yüksek miktarda sensör verisi üreten ve farklı değişkenlere bağlı olarak dinamik çalışma ortamlarına sahip sistemler için büyük avantaj sağlar. DL, İHA'ların görsel veri işleme, kestirimci bakım, uçuş optimizasyonu, anomali tespiti ve otonom kontrol sistemleri gibi birçok kritik alanında kullanılmaktadır.

İHA'lar, uçuş sırasında çeşitli sensörler aracılığıyla titreşim, sıcaklık, hava basıncı, motor performansı, rüzgâr şiddeti, hava akışı ve navigasyon verileri gibi birçok farklı parametreyi toplar. Bu verilerin büyük bir kısmı geleneksel istatistiksel yöntemlerle analiz edilmekteyken, daha kompleks ilişkileri ortaya çıkarmak ve gerçek zamanlı olarak karar mekanizmalarını iyileştirmek amacıyla DL tekniklerinden faydalanılmaktadır. Özellikle anomali tespiti ve kestirimci bakım gibi süreçlerde DL, sistemin normal ve anormal çalışma durumlarını otomatik olarak öğrenmesini sağlayarak, olası arızaların erken teşhis edilmesine olanak tanır.

İHA sistemlerinde DL'nin en yaygın kullanıldığı alanlardan biri görüntü işleme ve nesne tanıma sistemleridir. Özellikle askeri ve sivil operasyonlarda, İHA'ların insansız gözetleme, hedef takibi ve sınır güvenliği gibi görevlerde kullanılması, yüksek doğruluk oranına sahip görüntü işleme sistemlerini gerektirmektedir. DL tabanlı CNN, İHA'ların yüksek çözünürlüklü kameralar veya termal görüntüleme sistemleriyle aldığı görüntüleri analiz ederek nesne tespiti, arazi haritalama ve hedef belirleme gibi işlemleri insan müdahalesine gerek kalmadan gerçekleştirmesini sağlamaktadır. CNN modelleri, klasik ML tekniklerine kıyasla kenar belirleme, şekil algılama ve nesne segmentasyonu gibi görevlerde çok daha başarılı sonuçlar vermektedir. Bu bağlamda, İHA'lar tarafından çekilen görüntüler gerçek zamanlı olarak işlenerek, güvenlik tehditleri, hareketli nesneler ve anormal olaylar otomatik olarak algılanabilir.

Bunun yanı sıra, İHA sistemlerinde kestirimci bakım ve anomali tespitinde de DL tabanlı modeller giderek daha fazla kullanılmaktadır. Zaman serisi verilerinin analizi için RNN ve uzun kısa süreli bellek (LSTM) modelleri, İHA sensörlerinden gelen verileri kullanarak önceden meydana gelen arızalara dayalı olarak gelecekte oluşabilecek olası sorunları tahmin etmekte ve operatörleri önceden uyarmaktadır. Bu sayede, bakım süreçleri daha verimli hale gelirken, beklenmeyen arızaların neden olabileceği maliyetler de minimize edilmektedir. Örneğin, motor sıcaklıklarında

anormal artışlar, pervane titreşimlerinde düzensizlikler veya batarya performansındaki ani düşüşler, LSTM modelleri tarafından analiz edilerek sistemde meydana gelebilecek bir arızanın erken uyarı mekanizmasıyla tespit edilmesine olanak tanır.

İHA'ların otonom uçuş yeteneklerini artırmak için DRL algoritmalarından da faydalanılmaktadır. DRL, bir sistemin belirli bir ortamda deneyim kazanarak ödüllendirme mekanizmalarıyla en uygun kararları almasını sağlayan bir öğrenme yöntemidir. İHA'ların rüzgâr akımları, ani hava değişimleri ve engellerle karşılaşması gibi durumlarda en güvenli ve enerji verimli rotaları belirleyebilmesi için DRL tabanlı modeller kullanılmaktadır. Örneğin, bir İHA'nın en az enerji harcayarak belirli bir hedefe ulaşmasını sağlamak veya bir engelden kaçınarak yolunu değiştirmesi için en uygun manevrayı belirlemek, pekiştirmeli öğrenme algoritmaları ile optimize edilebilmektedir.


DL'nin İHA'lara sunduğu bir diğer önemli avantaj ise haberleşme ve veri iletimi optimizasyonudur. Geleneksel kablosuz haberleşme sistemleri, artan veri trafiği ve hava araçları arasındaki yoğun iletişim nedeniyle zaman zaman darboğaz yaşayabilmektedir. Ancak ANN, İHA'lar arasındaki haberleşme süreçlerini optimize ederek, veri paketlerinin daha verimli bir şekilde iletilmesini ve ağ yoğunluğunun azaltılmasını sağlayabilmektedir. Bu sayede, birden fazla İHA'nın aynı anda çalıştığı senaryolarda, haberleşme sistemlerinin güvenilirliği artırılarak veri kayıplarının önüne geçilmektedir.

DL teknikleri, İHA'ların operasyonel kabiliyetlerini artıran, kestirimci bakım süreçlerini iyileştiren ve otonom uçuş yeteneklerini geliştiren güçlü bir araçtır. Görüntü işleme, anomali tespiti, kestirimci bakım, uçuş optimizasyonu ve haberleşme sistemleri gibi birçok farklı alanda DL tabanlı çözümler, İHA'ların daha güvenilir ve akıllı bir şekilde çalışmasını sağlamaktadır. Özellikle derin pekiştirmeli öğrenme ve zaman serisi analizine dayalı kestirimci bakım sistemlerinin daha da geliştirilmesiyle, İHA'ların uzun vadeli kullanım ömrü artırılabilecek ve güvenilirlik seviyeleri en üst düzeye çıkarılacaktır.

4. MATERİYAL

4.1. İnsansız Hava Aracı Bileşenleri

İHA etkin ve güvenilir bir şekilde çalışabilmesi için birçok kritik bileşenin uyum içinde çalışması gerekmektedir (Şekil 21). Uçuş stabilitesini sağlamak, veri toplamak, enerji yönetimini düzenlemek ve görevlerin başarılı bir şekilde icra edilmesini mümkün kılmak adına bu bileşenlerin seçimi ve entegrasyonu büyük önem taşımaktadır.



Şekil 21. İnsansız Hava Aracı Bileşenleri

İHA'ların temel bileşenleri arasında gövde yapısı, motorlar, pervaneler, elektronik hız kontrol üniteleri (ESC), batarya, güç modülü, uçuş kontrol kartı, kumanda sistemi, telemetri birimi, GPS ve çeşitli sensörler yer almaktadır. Gövde yapısı, İHA'nın aerodinamik performansını belirlerken, motorlar ve pervaneler gerekli itkiyi sağlayarak aracın havada dengeli bir şekilde hareket etmesine olanak tanımaktadır. ESC, motorların dönüş hızlarını düzenleyerek uçuş kontrol mekanizmasının stabil çalışmasını desteklemektedir. Güç modülü, bataryadan gelen enerjiyi düzenleyerek sistemin ihtiyaç duyduğu elektrik gücünü güvenilir bir şekilde sağlamaktadır.

Uçuş kontrol kartı, İHA'nın tüm uçuş dinamiklerini yöneterek sensörlerden gelen verileri işleyen ve motorlara uygun komutları gönderen merkezi bir işlem birimidir. Kumanda sistemi, operatörün manuel veya otonom kontrol modlarında İHA'yı yönlendirmesine olanak tanımaktadır. Telemetri birimi, uçuş sırasında toplanan verilerin yer istasyonuna iletilmesini sağlayarak anlık takip ve veri analizi yapılmasına yardımcı olmaktadır. GPS sistemi, hassas konum belirleme ve rota takibi için kritik bir rol oynarken, farklı operasyonel gereksinimlere yönelik kullanılan çeşitli sensörler, çevresel değişkenlerin algılanmasını ve sistemin güvenilirliğinin artırılmasını sağlamaktadır.

Bu bileşenlerin uyum içinde çalışması, İHA'nın performansını doğrudan etkilemektedir. Yapısal malzemelerin hafifliği, elektronik sistemlerin enerji verimliliği ve haberleşme sistemlerinin güvenilirliği gibi faktörler, İHA'nın operasyonel kapasitesini belirlemektedir. Dolayısıyla, İHA bileşenleri, kullanım amacına uygun olarak optimize edilmeli ve sistem entegrasyonu dikkatli bir şekilde gerçekleştirilmelidir.

4.1.1. Gövde

İHA tasarımında, uçuş verilerinin gürültüsüz ve hassas bir şekilde elde edilmesini sağlamak amacıyla bileşenlerin optimize edilmesi kritik bir gerekliliktir. Bu optimizasyon, aracın yapısal dayanıklılığının artırılması, aerodinamik verimliliğin sağlanması ve titreşim kaynaklı sinyal gürültüsünün azaltılması açısından önem arz etmektedir. Özellikle, uçuş süresinin uzatılması ve sensör verilerinin doğruluk seviyesinin maksimize edilmesi açısından, gövde malzemesi seçimi ve tasarım parametreleri büyük bir hassasiyetle belirlenmelidir.

İHA gövdeleri genellikle metal, plastik ve karbon fiber gibi farklı malzemeler kullanılarak imal edilmektedir. Metal malzemeler, yüksek mekanik dayanıklılık sunmaları ve çarpışma dayanımlarının yüksek olması nedeniyle tercih edilse de, azami kalkış ağırlığını (MTOW) arttırması ve enerji tüketimini artırması gibi dezavantajlara sahiptir. Plastik malzemeler, hafiflikleri nedeniyle özellikle hobi amaçlı kullanımlarda tercih edilmekle birlikte, yapısal dayanıklılıklarının düşük olması nedeniyle profesyonel ve endüstriyel kullanım için yeterli performans sunmamaktadır.

Bu bağlamda, karbon fiber malzemeler öne çıkmaktadır. Karbon fiber, yoğunluk/ağırlık oranının düşük olmasına karşın, yüksek mekanik dayanım

sergilemesi nedeniyle havacılık ve uzay endüstrilerinde yaygın olarak tercih edilmektedir. Bunun yanında, karbon fiber gövdeler, yapısal rijitliği sağlarken aynı zamanda titreşim sönümleme kapasitesine de sahiptir. Titreşimlerin etkin bir şekilde absorbe edilmesi, uçuş verilerinin hassasiyetini arttırmakta ve sensörlerden elde edilen sinyallerin doğruluğunu iyileştirmektedir. Bu nedenle, uçuş verilerinin hassas bir şekilde toplanmasını sağlamak adına karbon fiber malzeme kullanımı uygun bir tercih olarak değerlendirilmektedir.

Bu tez çalışması kapsamında, yüksek taşıma kapasitesi, geniş yerleşim hacmi ve yapısal dayanımı nedeniyle MARK4 V3 Pro 15 Inch 680 mm T8 karbon fiber drone gövdesi tercih edilmiştir (Şekil 22). Seçilen gövde yapısı, geniş motor açıklığı sayesinde büyük çaplı pervane kullanımına olanak tanır. Modüler yapısı sayesinde sensör, güç dağıtım sistemi, veri toplama birimleri ve diğer elektronik bileşenlerin gövde üzerine dengeli şekilde yerleştirilmesine imkan sunmaktadır.



Şekil 22. MARK4 V3 Pro 15 Inch 680 mm T8 Karbon Fiber Drone Gövdesi

Gövde tasarımında, malzeme seçiminin yanı sıra yapısal ve aerodinamik tasarım faktörleri de önemlidir. Modülerlik ilkesi, gövde tasarımının kolay montaj ve sökme işlemlerine uygun olmasını sağlayarak çok yönlülüğü arttırmaktadır. Motor sürücülerinin ve diğer elektronik bileşenlerin optimize edilmiş konumlandırılması, gövdenin aerodinamik yapısını bozmadan verimli çalışmasını sağlamalıdır.

Ayrıca, pervane ve motor arasındaki mesafenin doğru belirlenmesi, itki kuvvetinin dengelenmesi ve uçuş stabilitesinin artırılması açısından kritik bir faktördür. Uzun kollar, pervaneler arasındaki mesafeyi arttırarak uçuş stabilitesini

iyileştirirken, daha kısa kollar ise düşük hacimli ve daha kompakt yapılar için avantaj sağlamaktadır. Özellikle küçük boyutlu İHA tasarımlarında, hem dayanıklı hem de hafif malzemelerin seçilmesi, enerji verimliliğinin optimize edilmesi açısından kritik bir gerekliliktir.

Sonuç olarak, karbon fiber malzemelerin hafiflik, mukavemet ve titreşim sönümleme gibi avantajları, İHA gövdelerinin aerodinamik performansını ve veri toplama hassasiyetini iyileştiren kritik unsurlar arasında yer almaktadır. Bu nedenle, özellikle bilimsel ve endüstriyel uçuş analizleri için karbon fiber gövde kullanımı en uygun tasarım yaklaşımı olarak değerlendirilmektedir. Tez kapsamında tercih edilen MARK4 V3 Pro 15 Inch 680 mm T8 karbon fiber gövde, yapısal dayanımı, düşük ağırlığı ve modüler entegrasyon kabiliyeti sayesinde geliştirilen veri toplama sisteminin güvenilir ve stabil şekilde çalışmasına katkı sağlamaktadır.

4.1.2. Motor

İHA için motor seçimi, aracın genel performansı, enerji verimliliği, manevra kabiliyeti ve uçuş stabilitesi üzerinde doğrudan etkili olan kritik bir bileşendir. Motorların sağladığı itki kuvveti, aracın kaldırma kapasitesini belirlerken, motor tipinin verimliliği ve güç-ağırlık oranı, uçuş süresi ve enerji tüketimi açısından belirleyici olmaktadır. İHA tasarımında, motor seçiminin optimize edilmesi, hem aerodinamik verimliliğin artırılması hem de operasyonel sürelerin maksimize edilmesi açısından büyük önem taşımaktadır.

Hava araçlarında kullanılan motorlar genel olarak fırçalı ve fırçasız olmak üzere iki ana kategoriye ayrılmaktadır. Fırçalı motorlar, mekanik komütasyon sistemine sahip olup fırça ve komütatör aracılığıyla elektrik enerjisini mekanik harekete dönüştürmektedir. Ancak, bu tip motorlar zamanla fırçaların aşınmasına bağlı olarak bakım gerektirir ve enerji kayıpları fırçalı yapı nedeniyle daha yüksek seviyelerde olabilir. Bu nedenle, uzun vadeli kullanımda verimlilik açısından dezavantaj oluşturabilmektedir. Düşük maliyetleri ve basit kontrolleri sayesinde bazı endüstriyel uygulamalarda hala tercih edilse de, yüksek verimlilik ve uzun ömür gerektiren sistemlerde fırçalı motorların sınırlamaları bulunmaktadır.

Fırçasız motorlar ise elektronik komütasyon kullanarak çalıştıklarından, mekanik sürtünme kaynaklı aşınma problemleri yaşamazlar. Bu özellik, motorların daha uzun ömürlü ve düşük bakım gerektiren bir yapıya sahip olmasını sağlamaktadır.

Ayrıca, fırçasız motorlar daha yüksek enerji verimliliği sunarak enerji kayıplarını minimize etmekte ve özellikle İHA gibi hassas sistemlerde daha stabil ve güvenilir bir performans sergilemektedir. Elektromanyetik girişim seviyesinin düşük olması, anlık tork yanıtının yüksek olması ve yüksek verimlilik sunması, hassas uçuş kontrolü gerektiren sistemlerde fırçasız motorları öne çıkaran önemli faktörlerdir. Bu motorlar, uzun süreli operasyonlarda güvenilirlik ve istikrar sağladığı için havacılık ve savunma sanayisinde yaygın olarak kullanılmaktadır.

Bu tez çalışması kapsamında, yüksek itki kapasitesi, düşük titreşim karakteristiği ve enerji verimliliği nedeniyle GEPRC EM4218 350KV fırçasız motor tercih edilmiştir (Şekil 23). Seçilen motor yapısı, özellikle ağır yük taşıma kapasitesine sahip orta ve büyük ölçekli İHA platformlarında stabil uçuş performansı sağlamaktadır. Düşük KV değerine sahip olması sayesinde büyük çaplı pervaneler ile uyumlu çalışabilmekte ve daha yüksek tork üretimi sağlayarak uçuş sırasında dengeli itki oluşumuna katkı sunmaktadır. Ayrıca motorun yüksek verimli elektromanyetik yapısı, enerji tüketimini optimize ederek daha uzun operasyon sürelerinin elde edilmesine olanak tanımaktadır.



Şekil 23. GEPRC EM4218 350KV Fırçasız Motor

İHA tasarımlarında, özellikle küçük ve orta ölçekli hava araçlarında, dört motorlu konfigürasyonlar (quadrotor) oldukça yaygın olarak tercih edilmektedir. Bu konfigürasyonda, iki motor saat yönünde (CW), iki motor ise saat yönünün tersine (CCW) dönüş yapacak şekilde konumlandırılmaktadır. Bu yerleşim, tork dengesinin

sağlanmasına ve stabil bir uçuş performansının elde edilmesine katkı sağlamaktadır. Bunun yanı sıra, motor yerleşimi için yaygın olarak X veya + dizilim modelleri tercih edilmekte olup, bu dizilimlerin her biri uçuş dinamikleri üzerinde farklı etkiler yaratmaktadır. X dizilimi, daha iyi manevra kabiliyeti sağlarken, + dizilimi daha dengeli bir uçuş profili sunmaktadır. Motor yerleşimindeki bu farklılıklar, İHA'nın görev tanımına göre belirlenmektedir.

Motor seçiminde, motor boyutu ve ağırlığının İHA'nın genel tasarımına uygun olması gerekmektedir. Daha büyük motorlar daha yüksek itki üretebilmekte, ancak aynı zamanda ağırlık ve enerji tüketimi açısından dezavantaj yaratabilmektedir. Ağırlığın artması, batarya tüketimini hızlandırarak operasyonel sürenin kısılmasına neden olmaktadır. Hafif motorlar ise azami kalkış ağırlığını (MTOW) minimize ederek uçuş süresini uzatmakta ve enerji verimliliğini arttırmaktadır. Bu bağlamda, motor seçiminin batarya kapasitesiyle uyumlu olması ve enerji yönetiminin optimal seviyede gerçekleştirilmesi kritik öneme sahiptir. Batarya-motor uyumu, motorların nominal çalışma gerilimlerine uygun şekilde belirlenmeli ve motorların sağladığı itki, taşıma kapasitesi ve güç tüketimi göz önünde bulundurularak tasarlanmalıdır.

Ayrıca, motorun termal yönetimi ve soğutma kapasitesi de göz önünde bulundurulmalıdır. Yüksek güç gereksinimi olan motorlar, aşırı ısınma problemi yaşayabilir ve bu durum motor verimini düşürerek uzun vadede hasarlara yol açabilir. Bu nedenle, etkin bir termal yönetim stratejisinin belirlenmesi, motorun sürekli yüksek performanslı çalışmasını sağlamak açısından gereklidir. GEPRC EM4218 350KV motorun sahip olduğu geniş stator yapısı ve yüksek kaliteli soğutma tasarımı, uzun süreli uçuş operasyonlarında termal kararlılığın korunmasına katkı sağlamaktadır.

İHA'ların tasarımında fırçasız motorlar, enerji verimliliği, bakım gereksiniminin düşük olması ve yüksek performans avantajları nedeniyle tercih edilmektedir. Motor seçiminde, aracın uçuş dinamikleri, faydalı yük kapasitesi ve enerji tüketimi dikkate alınarak optimum çözümler belirlenmelidir. İleri düzey hava araçlarında motor verimliliğini maksimize etmek için batarya ve güç yönetimi ile entegre bir tasarım süreci benimsenmelidir. Bu sayede, hem operasyonel süreler artırılabilir hem de güvenilir ve istikrarlı bir uçuş performansı sağlanabilir.


Tez kapsamında kullanılan GEPRC EM4218 350KV fırçasız motorlar, yüksek tork kapasitesi, düşük enerji tüketimi ve stabil çalışma karakteristikleri sayesinde geliştirilen İHA sisteminin uçuş performansına önemli katkılar sağlamaktadır.

Motorların karbon fiber gövde yapısı ve güç sistemi ile uyumlu şekilde çalışması, titreşim seviyelerinin azaltılmasına, enerji verimliliğinin artırılmasına ve gerçek zamanlı veri toplama süreçlerinin daha kararlı şekilde gerçekleştirilmesine olanak tanımaktadır.

4.1.3. Elektronik Hız Kontrol Ünitesi

ESC, İHA motorların hızını, torkunu ve güç dağılımını düzenleyen kritik bir bileşendir. ESC, bataryadan aldığı enerjiyi uygun frekans ve voltaj seviyesinde motorlara ileterek motor hızının hassas bir şekilde kontrol edilmesini sağlamaktadır. Bu nedenle, ESC'nin motor ve batarya ile tam uyumlu olacak şekilde seçilmesi gerekmektedir. İHA sistemlerinde, ESC'nin motorun çalışma dinamiklerine uygun olarak belirlenmesi, sistem performansının artırılması ve güvenilir uçuş sağlanması açısından önem arz etmektedir.

Bu tez çalışması kapsamında, motor kontrol süreçlerinde yüksek verimlilik ve senkronize güç dağılımı sağlamak amacıyla GEPRC 4IN1 ESC tercih edilmiştir (Şekil 24). Seçilen 4'ü 1 arada ESC yapısı, dört motorun tek bir entegre kart üzerinden kontrol edilmesine olanak tanıyarak hem ağırlık optimizasyonu hem de kablolama karmaşıklığının azaltılması açısından önemli avantajlar sunmaktadır. Ayrıca yüksek akım kapasitesine sahip yapısı sayesinde, GEPRC EM4218 350KV motorların ihtiyaç duyduğu güç gereksinimlerini kararlı şekilde karşılayabilmektedir.



Şekil 24. GEPRC 4IN1 ESC

ESC seçiminde en kritik faktörlerden biri, desteklediği akım değerinin motorun maksimum akım çekiş kapasitesinden yüksek olması gerekliliğidir. Eğer ESC'nin akım kapasitesi motorun ihtiyaç duyduğundan düşük olursa, aşırı ısınma

meydana gelebilir ve bu durum ESC'nin uzun vadede arızalanmasına neden olabilir. Özellikle yüksek güçlü motorlar daha fazla akım çektiğinden, uygun akım kapasitesine sahip ESC seçimi, sistem güvenliği açısından büyük önem taşımaktadır. Aşırı ısınmanın önlenmesi için bazı ESC modellerinde sıcaklık sensörleri ve otomatik termal koruma mekanizmaları bulunmaktadır. Bu tür koruma mekanizmaları, ESC'nin belirli sıcaklık eşiklerini aşması durumunda gücü düşürerek aşırı ısınmayı engelleyebilmektedir.

İHA'larda yaygın olarak kullanılan fırçasız motorlar için ESC'ler, elektronik komütasyon prensibine göre çalışmaktadır. Bu nedenle, fırçasız motorlu bir İHA sisteminde yalnızca fırçasız ESC'lerin kullanılması gerekmektedir. ESC seçiminde yalnızca akım kapasitesi değil, aynı zamanda voltaj uyumluluğu da dikkate alınmalıdır. ESC'nin, İHA'nın güç kaynağı olan batarya ile uyumlu voltaj seviyelerini desteklemesi gerekmektedir. Batarya-ESC uyumsuzluğu, motor performansında dalgalanmalara yol açabileceği gibi, ESC'nin aşırı yüklenmesine ve verim kayıplarına da neden olabilir.

İHA uçuş güvenliği açısından, ESC'lerin düşük voltaj koruma mekanizmasına sahip olması da önemli bir gerekliliktir. Bataryanın uçuş sırasında voltaj seviyesinin belirli bir eşik değerin altına düşmesi, motorların dengesiz çalışmasına ve uçuş stabilitesinin bozulmasına neden olabilir. Düşük voltaj koruma özelliğine sahip ESC'ler, belirlenen eşik seviyesine ulaşıldığında motor gücünü kademeli olarak azaltarak bataryanın zarar görmesini önlemekte ve uçuş süresinin güvenli bir şekilde tamamlanmasını sağlamaktadır.

ESC'lerin programlanabilir olması, farklı uçuş senaryolarına uygun şekilde özelleştirilmesine olanak tanımaktadır. Örneğin, tarımsal İHA uygulamalarında ESC'nin belirli bir hızda sabit kalmasını sağlayarak ilaçlama işlemlerinde eşit dağılım elde edilmesi mümkündür. Arama kurtarma operasyonlarında, ESC'ler düşük güç tüketimi modlarında çalışacak şekilde programlanarak İHA'nın havada kalış süresi uzatılabilir. Benzer şekilde, veri toplama amaçlı uçuşlar gerçekleştiren İHA'larda, ESC'lerin optimize edilmesi titreşimsiz ve stabil bir uçuş performansı sağlayarak sensörlerden elde edilen verinin doğruluğunu artırmaktadır.

ESC seçiminde bir diğer önemli faktör ise sinyal kaybı koruma mekanizmasıdır. İHA'ların uçuş sırasında ESC'nin sinyal kaybı yaşaması, kontrol kaybına ve sistemin dengesiz hale gelmesine neden olabilir. Sinyal kaybı koruma

özelliğine sahip ESC'ler, ani sinyal kesilmeleri durumunda motor gücünü kısarak veya belirlenen sabit bir hızda çalıştırarak sistemin güvenliğini sağlar. Böylece, kontrol kaybı riskleri minimize edilerek stabil ve güvenli bir uçuş gerçekleştirilmektedir.

4.1.4. Batarya

Batarya, İHA'da güç kaynağı olarak kullanılan temel bileşenlerden biridir. Motorlara, ESC ünitelerine ve diğer uçuş bileşenlerine enerji sağlayarak İHA'nın operasyonel süresini ve performansını doğrudan etkiler. İHA'larda kullanılan bataryalar genellikle yüksek enerji yoğunluğu, hafiflik ve uzun ömür gereksinimlerine uygun olacak şekilde seçilmektedir.

Bu tez çalışması kapsamında, yüksek enerji kapasitesi ve uzun süreli uçuş performansı sağlamak amacıyla 6S 16000 mAh Li-Po batarya tercih edilmiştir (Şekil 25). Seçilen batarya yapısı, yüksek akım gereksinimine sahip motor ve ESC sistemlerine kararlı enerji sağlayabilmekte ve geliştirilen İHA platformunun uzun süreli görevlerde stabil şekilde çalışmasına katkı sunmaktadır. 6S hücre konfigürasyonu sayesinde yüksek voltaj çıkışı elde edilirken, 16000 mAh kapasite değeri sistemin uçuş süresinin artırılmasına olanak tanımaktadır.



Şekil 25. 6S 16000 mAh Li-Po Batarya

Batarya seçimi, İHA'nın görev profiline, uçuş süresine, yük kapasitesine ve enerji ihtiyacına göre belirlenmelidir. Lityum Polimer (Li-Po) ve Lityum İyon (Li-Ion) bataryalar, İHA sistemlerinde en yaygın kullanılan batarya türleridir. Li-Po bataryalar, yüksek deşarj oranlarına sahip olup kısa sürede yüksek akım sağlayabilme yeteneği ile öne çıkmaktadır. Bu özellik, yüksek itki gücü gerektiren İHA'larda avantaj

sağlamaktadır. Li-Ion bataryalar ise enerji yoğunluğu açısından daha yüksek kapasite sunarak uzun uçuş süreleri elde edilmesini mümkün kılmaktadır.

Bataryanın nominal voltajı, hücre sayısına bağlı olarak belirlenir. Örneğin, dört hücreli (4S) bir Li-Po batarya yaklaşık 14.8V nominal gerilime sahiptir. Batarya voltajının, motor ve ESC ile tam uyumlu olması gerekmektedir. Uyumsuzluk durumunda sistem bileşenlerinde aşırı yüklenme, performans kaybı ve potansiyel güvenlik riskleri ortaya çıkabilir. Tez kapsamında kullanılan 6S Li-Po batarya yaklaşık 22.2V nominal gerilim sağlayarak GEPRC EM4218 350KV motorlar ve GEPRC 4IN1 ESC sistemi ile uyumlu bir güç altyapısı oluşturmaktadır.

Batarya kapasitesi (mAh cinsinden), İHA'nın uçuş süresini belirleyen en önemli faktörlerden biridir. Yüksek kapasiteli bataryalar daha uzun uçuş süreleri sunarken, aynı zamanda ağırlık artışına neden olabilir. Ağırlık, İHA'nın taşıma kapasitesini ve manevra kabiliyetini doğrudan etkilediğinden, batarya kapasitesi ile ağırlık arasında dengeli bir seçim yapılmalıdır. 16000 mAh kapasiteye sahip batarya yapısı, geliştirilen İHA sisteminde hem yeterli uçuş süresi sağlamak hem de veri toplama sistemlerinin kesintisiz çalışmasına olanak tanımaktadır.

Batarya güvenliği de kritik bir konudur. Aşırı şarj, aşırı deşarj ve aşırı ısınma durumları batarya ömrünü kısaltabilir ve potansiyel yangın riskine neden olabilir. Bu nedenle, bataryaların düşük voltaj koruma mekanizmalarına sahip olması, uygun şarj cihazları ile şarj edilmesi ve sıcaklık yönetimi açısından izlenmesi gerekmektedir. Ayrıca, yüksek akım çeken İHA sistemlerinde batarya bağlantılarının sağlam olması ve kaliteli güç dağıtım bileşenleri ile desteklenmesi, enerji kaybını minimize etmek ve sistem güvenliğini artırmak açısından önemlidir.

4.1.5. Pervane

Pervaneler, İHA uçuş performansını doğrudan etkileyen temel bileşenlerden biridir. İHA'ların hareketi, pervanelerin dönerek hava akımı oluşturmaları ve bu sayede itki kuvveti meydana getirmesiyle sağlanmaktadır. Pervane tasarımı, itki üretimi, verimlilik, manevra kabiliyeti ve genel uçuş dinamikleri açısından kritik bir rol oynamaktadır.

Bu tez çalışması kapsamında, yüksek itki verimliliği ve stabil uçuş performansı sağlamak amacıyla HQProp 15 inç pervane tercih edilmiştir (Şekil 26). Seçilen pervane yapısı, büyük çaplı tasarımı sayesinde daha fazla hava kütlelerini hareket

ettirerek yüksek kaldırma kuvveti oluşturabilmektedir. Geniş çaplı pervane yapısı düşük devirlerde daha yüksek itki üreterek enerji verimliliğinin artırılmasına katkı sunmaktadır.



Şekil 26. HQProp 15 İnç Pervane

İHA sistemlerinde kullanılan pervaneler genellikle malzeme, geometrik yapı, çap ve adım açısı gibi faktörlere bağlı olarak sınıflandırılmaktadır. Pervane seçimi yapılırken, motorun sağladığı tork ve devir sayısı ile uyumlu olması gerekmektedir. Yanlış seçilen pervaneler, motorun verimli çalışmasını engelleyerek güç kayıplarına ve enerji tüketiminin artmasına neden olabilir.

Pervane malzemesi, dayanıklılık, ağırlık ve titreşim sönümlleme açısından önem taşımaktadır. Genel olarak karbon fiber, kompozit malzemeler ve plastik pervaneler yaygın olarak tercih edilmektedir. Karbon fiber pervaneler, hafif olmaları ve yüksek mukavemet sunmaları nedeniyle özellikle yüksek performans gerektiren uygulamalarda kullanılmaktadır. Plastik pervaneler ise daha düşük maliyetli olup hobi amaçlı veya düşük yük kapasiteli sistemlerde yaygın olarak kullanılmaktadır. Malzeme seçimi, uçuş süresi, dayanıklılık ve sistemin genel ağırlık dengesi açısından değerlendirilmelidir. Tez kapsamında kullanılan HQProp 15 inç pervaneler, hafif yapı ve yüksek rijitlik sağlayan kompozit malzeme özellikleri sayesinde titreşim seviyelerinin azaltılmasına katkı sağlamaktadır.

Pervane çapı ve adım açısı, pervanenin hava akışına karşı oluşturduğu tepkime kuvvetini belirleyen kritik faktörlerdir. Daha büyük çaplı pervaneler, daha fazla hava kütlesini hareket ettirerek yüksek itki üretirken, daha fazla enerji tüketebilir. Küçük

çaplı pervaneler ise daha düşük itki üretmesine rağmen motor devir sayısını artırarak yüksek hızda daha iyi performans gösterebilir. Pervane adım açısı, pervanenin bir tam turda aldığı mesafeyi ifade eder ve bu açı büyüdükçe pervanenin daha fazla itki üretmesi sağlanır. Ancak, fazla büyük açılar motor yükünü artırarak enerji verimliliğini olumsuz etkileyebilir.

İHA pervaneleri genellikle iki, üç veya dört kanatlı yapılar halinde üretilmektedir. İki kanatlı pervaneler, daha az hava direnci oluşturarak yüksek hızlara ulaşmada avantaj sağlarken, üç veya dört kanatlı pervaneler daha stabil bir uçuş performansı sunarak manevra kabiliyetini artırmaktadır. Kanat sayısının artması, titreşimi azaltarak sensör verilerinin doğruluğunu iyileştirebilir ancak motor üzerindeki yükü artırarak enerji tüketimini yükseltebilir.


Pervane seçimi, İHA'nın kullanım amacına göre optimize edilmelidir. Örneğin, uzun menzilli keşif görevlerinde yüksek verimli ve düşük enerji tüketimine sahip pervaneler tercih edilirken, yüksek manevra kabiliyeti gerektiren uygulamalarda daha stabil uçuş sağlayan çok kanatlı pervaneler kullanılmaktadır. Ayrıca, pervanelerin aerodinamik tasarımı, hava akımını optimize ederek türbülansı minimize etmeli ve uçuş esnasında oluşabilecek gürültüyü azaltacak şekilde tasarlanmalıdır. Bu tez çalışması kapsamında kullanılan HQProp 15 inç pervaneler, GEPRC EM4218 350KV motorlar ile uyumlu çalışarak yüksek itki verimliliği, düşük titreşim seviyesi ve kararlı uçuş performansı sağlamaktadır.

4.1.6. Uçuş Kontrol Kartı

Uçuş kontrol kartı, İHA stabilitesini ve manevra kabiliyetini sağlayan temel bileşenlerden biridir. İHA'nın uçuş dinamiklerini yöneterek motor hızlarını, yönlendirme sistemlerini ve sensör verilerini işleyerek istikrarlı bir uçuş gerçekleştirilmesine olanak tanır. Uçuş kontrol kartları, çeşitli sensörlerden gelen verileri sürekli olarak analiz ederek hava aracının kararlılığını sağlamak ve dış etkenlere karşı gerekli düzeltmeleri yapmak amacıyla çalışır.

Bu tez çalışması kapsamında, yüksek işlem kapasitesi, gelişmiş sensör entegrasyonu ve kararlı uçuş performansı nedeniyle SpeedyBee F405 uçuş kontrol kartı tercih edilmiştir (Şekil 27). Seçilen uçuş kontrol kartı, STM32F405 işlemci altyapısı sayesinde sensörlerden elde edilen verileri yüksek hızda işleyebilmekte ve motor kontrol sistemlerine düşük gecikmeli komut iletimi sağlayabilmektedir. Ayrıca,

kompakt yapısı ve gelişmiş bağlantı seçenekleri sayesinde geliştirilen İHA platformunda veri toplama sistemleri ve diğer elektronik bileşenlerle uyumlu şekilde çalışabilmektedir.



Şekil 27. SpeedyBee F405 Uçuş Kontrol Kartı

Bir uçuş kontrol kartının en önemli işlevlerinden biri, İHA'nın farklı eksenlerde hareketlerini algılamak ve bu hareketlere uygun tepkiler oluşturmaktır. Bu doğrultuda, jiroskop, ivmeölçer, manyetometre ve barometre gibi çeşitli sensörler ile entegre bir şekilde çalışmaktadır. Jiroskop, hava aracının açısal hızını ölçerek yön değişimlerini algılar. İvmeölçer, İHA'nın hareket doğrultusundaki ivmelenme değişikliklerini belirleyerek stabil uçuş için gerekli düzeltmeleri yapar. Manyetometre, manyetik alan değişimlerini tespit ederek pusula yönlendirmesi sağlar. Barometre ise irtifa değişimlerini ölçerek yükseklik kontrolünün daha hassas yapılmasına yardımcı olur.

Uçuş kontrol kartları, genellikle belirli bir işlemci veya mikrodenetleyici tarafından yönetilir. Bu işlemci, sensörlerden gelen verileri anlık olarak işleyerek motorlara ve diğer uçuş bileşenlerine komutlar iletir. Gerçek zamanlı çalışan bu sistemler, özellikle dış etkenlerden kaynaklanan dengesizlikleri minimize etmek ve aracın stabilitesini artırmak amacıyla hızlı ve doğru karar mekanizmalarına sahiptir. Uçuş kontrol algoritmaları, genellikle Oransal-Türevsel-İntegral (PID) tabanlı olup, İHA'nın istenilen konum ve hızda kalmasını sağlamak için hata geri besleme

mekanizmaları kullanır. SpeedyBee F405 uçuş kontrol kartı, yüksek işlem gücü sayesinde PID kontrol algoritmalarının hızlı ve kararlı şekilde çalıştırılmasına olanak tanımakta ve uçuş sırasında oluşabilecek ani denge değişimlerine hızlı tepki verebilmektedir.

İHA'nın farklı modlarda uçuş gerçekleştirebilmesi için uçuş kontrol kartları çeşitli yazılımsal ve donanımsal özellikler içermektedir. Örneğin, manuel, yarı otomatik ve tam otomatik uçuş modları gibi seçenekler sunarak kullanıcının ihtiyacına göre farklı kontrol seviyeleri sağlar. Manuel modda, tüm kontrol operatör tarafından gerçekleştirilirken, yarı otomatik modda belirli stabilizasyon ve yönlendirme işlemleri sistem tarafından desteklenmektedir. Tam otomatik uçuş modlarında ise, önceden belirlenen bir rotaya göre otonom uçuş gerçekleştirilerek minimum operatör müdahalesi ile görev icra edilir.

Uçuş kontrol kartları aynı zamanda haberleşme modülleri ile donatılarak, yer kontrol istasyonu ile veri alışverişi sağlayabilir. Kablosuz iletişim teknolojileri kullanılarak, operatör uçuş esnasında anlık veri takibi yapabilir ve gerektiğinde müdahale edebilir. Bu haberleşme modülleri, radyo frekans tabanlı olabileceği gibi, daha gelişmiş sistemlerde telemetri veya uydu tabanlı iletişim teknolojileri ile de desteklenebilir.

Ayrıca, uçuş kontrol kartları güvenlik mekanizmaları içermektedir. Olası bir sinyal kaybı durumunda, sistemin otomatik olarak güvenli iniş yapmasını sağlayan acil durum prosedürleri mevcuttur. Batarya seviyesinin kritik eşiklerin altına düşmesi veya sensör verilerinde anormal sapmalar tespit edilmesi halinde, uçuş kontrol kartı güvenli iniş algoritmalarını devreye sokarak İHA'nın zarar görmesini engellemeye yönelik önlemler almaktadır. Bu tez çalışması kapsamında kullanılan SpeedyBee F405 uçuş kontrol kartı, gelişmiş güvenlik ve stabilizasyon altyapısı sayesinde uçuş güvenliğinin artırılmasına ve gerçek zamanlı veri toplama süreçlerinin daha güvenilir şekilde gerçekleştirilmesine katkı sağlamaktadır.

4.1.7. Telemetri

Telemetri, İHA uçuş sırasında toplanan verilerin gerçek zamanlı olarak yer kontrol istasyonuna iletilmesini sağlayan kritik bir haberleşme sistemidir. Uçuş güvenliği, sistem performansı ve operasyonel verimliliğin artırılması açısından önemli bir bileşendir. Telemetri sistemleri, İHA'nın pozisyonu, hız bilgisi, batarya durumu,

motor performansı, sensör verileri ve diğer uçuş parametrelerini anlık olarak ileterek operatörlerin durumu sürekli olarak izlemesine olanak tanır.

Bu tez çalışması kapsamında, güvenilir veri iletimi ve kararlı haberleşme altyapısı sağlamak amacıyla SIYI alıcı-verici telemetri sistemi tercih edilmiştir (Şekil 28). Seçilen telemetri sistemi, yer kontrol istasyonu ile İHA arasında çift yönlü veri haberleşmesi sağlayarak uçuş sırasında anlık veri takibinin gerçekleştirilmesine olanak tanımaktadır. Ayrıca düşük gecikmeli haberleşme altyapısı sayesinde sensör verileri, uçuş parametreleri ve sistem durum bilgileri gerçek zamanlı olarak operatöre aktarılabilmektedir.



Şekil 28. SIYI Alıcı-Verici Telemetri

Telemetri sistemleri, genellikle kablosuz haberleşme teknolojileri ile çalışmaktadır. Radyo frekans tabanlı iletişim sistemleri, yer kontrol istasyonu ile İHA arasında veri alışverişini sağlamak için yaygın olarak kullanılmaktadır. Bunun yanı sıra, gelişmiş İHA sistemlerinde telemetri verileri uydu tabanlı haberleşme sistemleri aracılığıyla da iletilebilmektedir. Kullanılan haberleşme protokolü, iletilen verinin doğruluğunu ve güvenilirliğini koruyarak uçuş sürecinde sürekli bağlantının sağlanmasını hedeflemektedir.

Telemetri sistemleri, uçuş operasyonları sırasında hem veri iletimi hem de geri bildirim mekanizmaları ile kritik kararların alınmasına yardımcı olmaktadır. Örneğin,

batarya seviyesinin belirlenen eşik değerlerinin altına düşmesi durumunda, telemetri sistemi bu bilgiyi yer kontrol istasyonuna ileterek operatörün gerekli önlemleri almasını sağlar. Benzer şekilde, motor sıcaklıklarının anormal seviyelere ulaşması halinde telemetri sistemleri aracılığıyla bu durum rapor edilerek acil müdahale süreçleri devreye sokulabilir.

İHA telemetri sistemleri, genellikle çift yönlü iletişim yeteneğine sahiptir. Bu sayede, operatör yalnızca İHA'dan veri almakla kalmaz, aynı zamanda uçuş sırasında belirli komutları İHA'ya ileterek anlık değişiklikler yapabilir. Bu özellik, uçuş rotasının değiştirilmesi, belirli sensörlerin aktif hale getirilmesi veya iniş prosedürlerinin başlatılması gibi senaryolarda büyük avantaj sağlamaktadır.

Telemetri sistemlerinde kullanılan frekans aralıkları, iletim mesafesi ve veri iletim hızına doğrudan etki etmektedir. Daha düşük frekanslar, daha uzun menzilli iletişim sağlarken, yüksek frekanslar daha fazla veri aktarım kapasitesine sahiptir ancak menzil açısından daha sınırlıdır. Uzun mesafeli uçuşlarda, telemetri sistemlerinin optimize edilmesi ve haberleşme kesintilerine karşı güvenlik mekanizmalarının devreye alınması gerekmektedir.

Güvenlik açısından, telemetri sistemleri şifreleme yöntemleri kullanarak veri iletimini yetkisiz erişimlere karşı koruma altına almalıdır. Şifrelenmemiş telemetri verileri, kötü niyetli müdahalelere açık olabilir ve sistem güvenliğini riske atabilir. Bu nedenle, modern İHA sistemlerinde güvenli haberleşme protokolleri ve veri bütünlüğünü sağlayan algoritmalar kullanılmaktadır.

Telemetri sistemlerinin entegrasyonu, yer kontrol istasyonları ile uyumlu bir şekilde gerçekleştirilmelidir. Uçuş yazılımları, telemetri verilerini anlık olarak analiz edebilmekte ve bu veriler grafiksel arayüzler aracılığıyla operatörlere sunulmaktadır. Böylece, operatörler İHA'nın durumu hakkında anlık bilgilere erişerek uçuş sırasında bilinçli kararlar alabilmektedir.

4.1.8. GPS

GPS, İHA navigasyon, konum belirleme ve uçuş kontrolü gibi kritik işlevleri yerine getiren temel bir teknolojidir. GPS, uydu tabanlı bir sistem olup, dünya yörüngesinde bulunan uydular aracılığıyla konum bilgisinin hassas bir şekilde elde edilmesini sağlar. İHA'ların otonom uçuş gerçekleştirmesi, rota takibi yapması ve

belirlenen koordinatlara hassas iniş gerçekleştirebilmesi için GPS sistemleri büyük bir öneme sahiptir.

Bu tez çalışması kapsamında, hassas konumlandırma ve güvenilir navigasyon performansı sağlamak amacıyla Readytosky Ublox NEO M8N GPS modülü tercih edilmiştir (Şekil 29). Seçilen GPS modülü, yüksek hassasiyetli uydu konumlandırma yeteneği sayesinde İHA'nın gerçek zamanlı konum bilgilerinin doğru şekilde elde edilmesine olanak tanımaktadır. Ayrıca, düşük sinyal kaybı ve hızlı uydu bağlantı kapasitesi sayesinde uçuş sırasında kararlı navigasyon performansı sunmaktadır.



Şekil 29. Readytosky Ublox NEO M8N GPS

GPS alıcıları, yeryüzündeki bir noktaya olan mesafelerini belirlemek için en az dört farklı uydudan gelen sinyalleri kullanarak üçgenleme (trilaterasyon) yöntemiyle konum bilgisi hesaplamaktadır. Bu hesaplama sonucunda İHA'nın enlem, boylam ve irtifa bilgileri elde edilir. GPS sistemleri, genellikle yerleşik bir işlemci ve anten yapısı ile entegre edilerek İHA'nın uçuş bilgisayarına doğrudan veri sağlayan bir yapıda çalışmaktadır.

GPS'in İHA'lar için sunduğu en önemli avantajlardan biri, hassas navigasyon sağlamasıdır. Bu sayede, önceden belirlenen bir uçuş planı doğrultusunda İHA'nın otonom olarak hareket etmesi mümkündür. GPS destekli sistemler, hava aracının belirli bir rotayı takip etmesini, istenilen bir noktada havada sabit kalmasını (hovering) ve hava koşullarından etkilenmeden stabil bir uçuş gerçekleştirmesini sağlar.

GPS, yalnızca konum belirleme amacıyla değil, aynı zamanda hız ve zaman senkronizasyonu için de kullanılmaktadır. İHA'nın anlık hız bilgisi GPS sinyalleri aracılığıyla hesaplanarak uçuş kontrol sistemine iletilir. Böylece, rüzgâr gibi dış etkenlere bağlı hız değişimleri tespit edilerek gerekli düzeltmeler yapılabilir. Ayrıca, GPS sinyalleri zamana duyarlı işlemler için yüksek hassasiyet sunarak, çoklu İHA operasyonlarında ve formasyon uçuşlarında zaman senkronizasyonunun sağlanmasına katkıda bulunur.

GPS sistemleri, bazen sinyal kaybı veya dış etkenler nedeniyle kesintilere uğrayabilir. Örneğin, elektromanyetik parazitler, yoğun bulut örtüsü veya radyo sinyal engellemeleri, GPS alıcısının doğru veri elde etmesini zorlaştırabilir. Bu tür durumların önüne geçmek için gelişmiş İHA sistemlerinde GPS verileri, ataletsel navigasyon sistemleri (INS) ve barometrik sensörler ile desteklenerek daha güvenilir bir konumlandırma sağlanmaktadır. Bu hibrit sistemler, GPS sinyali kaybolduğunda dahi İHA'nın stabil uçuş gerçekleştirmesine olanak tanır.

GPS teknolojisi, özellikle uzun menzilli görevler ve hassas iniş gerektiren uygulamalar için kritik öneme sahiptir. Tarımsal ilaçlama, haritalama, arama-kurtarma operasyonları ve askeri gözetleme gibi birçok alanda GPS destekli İHA'lar etkin bir şekilde kullanılmaktadır. GPS tabanlı sistemler, coğrafi bilgi sistemleri (CBS) ile entegre edilerek veri toplama süreçlerini daha verimli hale getirebilir. Bu tez çalışması kapsamında kullanılan Readytosky Ublox NEO M8N GPS modülü, uçuş kontrol kartı ve telemetri sistemi ile entegre çalışarak geliştirilen İHA platformunun navigasyon doğruluğunu ve operasyonel güvenilirliğini artırmaktadır.

4.1.9. Kumanda

Kumanda, İHA uzaktan kontrol edilmesini sağlayan temel bileşenlerden biridir. İHA'nın uçuş dinamiklerinin yönetilmesi, yönlendirilmesi ve belirlenen görevleri yerine getirebilmesi için kumanda sistemi kritik bir rol oynamaktadır. Kumanda sistemleri, operatörün İHA ile çift yönlü iletişim kurmasını sağlayarak komutların anlık olarak iletilmesine ve uçuş verilerinin geri bildirilmesine olanak tanır.

Bu tez çalışması kapsamında, uzun menzilli haberleşme, düşük gecikmeli veri aktarımı ve gelişmiş kontrol kabiliyeti sağlamak amacıyla SIYI MK15 kumanda sistemi tercih edilmiştir (Şekil 30). Seçilen kumanda sistemi, gelişmiş alıcı-verici altyapısı sayesinde uçuş kontrol kartı ve telemetri sistemi ile entegre çalışarak

güvenilir veri iletişimi sağlamaktadır. Ayrıca ergonomik tasarımı ve gelişmiş kontrol arayüzü sayesinde operatörün uçuş sırasında hassas kontrol gerçekleştirmesine olanak tanımaktadır.



Şekil 30. SIYI MK15 Kumanda

Kumanda sistemleri, temel olarak verici (transmitter) ve alıcı (receiver) bileşenlerinden oluşmaktadır. Verici, operatör tarafından yapılan komutları kablosuz sinyaller aracılığıyla İHA'ya iletirken, alıcı bu sinyalleri alarak uçuş kontrol kartına yönlendirir. Bu süreç, gerçek zamanlı olarak gerçekleştiğinden, kumanda sistemlerinin gecikme süresi düşük olmalı ve kesintisiz haberleşme sağlamalıdır.

Kumanda sistemleri, genellikle radyo frekansı üzerinden çalışmaktadır. Kullanılan frekans aralıkları, sinyal menzili ve veri aktarım hızını doğrudan etkilemektedir. Düşük frekanslar, daha uzun menzil sağlarken, yüksek frekanslar daha hızlı veri iletimi sağlayarak hassas kontrol mekanizmalarına olanak tanır. Uzun menzilli uçuşlar için, güçlü sinyal iletimi ve parazitlerden etkilenmeyen iletişim protokolleri kullanılmalıdır.

Kumanda sistemlerinde en önemli faktörlerden biri, güvenilir ve stabil bir bağlantının sağlanmasıdır. Sinyal kaybı veya parazitlenme durumunda, İHA'nın kontrolü kaybolabilir ve beklenmeyen durumlar meydana gelebilir. Bu tür riskleri

minimize etmek amacıyla, modern kumanda sistemleri sinyal kaybı durumunda otomatik dönüş veya acil iniş gibi güvenlik protokollerine sahiptir.

İHA’larda kullanılan kumandalar genellikle farklı kontrol modları sunmaktadır. Manuel modda, operatör tüm uçuş kontrollerini doğrudan kumanda aracılığıyla gerçekleştirirken, yarı otomatik ve tam otomatik modlarda belirli fonksiyonlar otomatik hale getirilebilir. Örneğin, yarı otomatik modda, kumanda sinyalleri uçuş kontrol kartı tarafından desteklenerek stabilizasyon sağlanırken, tam otomatik modda İHA, önceden belirlenen bir rotayı izleyerek minimal operatör müdahalesi ile uçuş gerçekleştirebilir.

Kumanda sistemlerinde ergonomi ve kullanım kolaylığı da önemli bir faktördür. Operatörün rahat bir şekilde kontrol sağlayabilmesi için kumanda yüzeyi, buton yerleşimi ve hassasiyet ayarları optimize edilmelidir. Uzun süreli operasyonlarda, kumandanın hafif ve ergonomik tasarıma sahip olması, operatörün yorulmasını engelleyerek daha verimli bir uçuş yönetimi sağlamaktadır.

Bazı gelişmiş kumanda sistemleri, telemetri verilerini de içerecek şekilde çift yönlü iletişim sağlamaktadır. Bu sayede, operatör anlık olarak batarya durumu, hız, irtifa, motor performansı gibi kritik verilere erişebilir ve uçuş parametrelerini gerçek zamanlı olarak optimize edebilir. Bu özellik, özellikle uzun menzilli ve hassas görevler için büyük avantaj sağlamaktadır.

4.1.10. Sensörler

Sensörler, İHA çevresel koşulları algılamasını, uçuş stabilitesini sağlamasını ve otonom hareket kabiliyetini artırmasını sağlayan temel bileşenlerdir. Sensörler, uçuş sırasında anlık veri toplayarak uçuş kontrol kartına iletir ve bu veriler, İHA’nın rotasını, dengesini ve genel performansını optimize etmek için kullanılır. Sensör sistemleri, İHA’ların güvenliğini artırırken, görev başarısını da doğrudan etkileyen kritik unsurlar arasında yer almaktadır.

İHA sistemlerinde kullanılan sensörler, genellikle işlevlerine göre farklı kategorilere ayrılmaktadır. Bunlar, ataletsel ölçüm sensörleri, çevresel sensörler, konum belirleme sensörleri ve görsel algılama sensörleri olarak sınıflandırılabilir.

Ataletsel ölçüm birimi (IMU), İHA’nın hareketlerini ve yönelimini ölçmek için kullanılan temel bir sensör sistemidir. IMU, jiroskop, ivmeölçer ve bazen manyetometre bileşenlerinden oluşmaktadır. Jiroskop, açısal hızları ölçerek İHA’nın

yön deęişimlerini belirlerken, ivmeölçer aracın ivmelenmesini ve eğimini algılar. Manyetometre, manyetik alan deęişimlerini tespit ederek İHA'nın pusula yönlendirmesini sağlar. Bu sensörler, uçuş stabilitesinin korunması ve otonom navigasyon süreçlerinde kritik rol oynamaktadır.

Çevresel Sensörler İHA'ların uçuş güvenliğini artırmak ve çevresel deęişkenleri algılamak amacıyla çeşitli çevresel sensörler kullanılmaktadır. Barometre, hava basıncını ölçerek İHA'nın irtifa bilgisini belirlemesine yardımcı olur. Termal sensörler, sıcaklık deęişimlerini algılayarak batarya yönetimi ve motor soğutma süreçlerinde önemli rol oynar. Nem sensörleri, hava koşullarının deęişimlerini tespit ederek sistem bileşenlerinin çalışma performansını optimize edebilir.

Konum sensörleri, İHA'nın küresel konumlandırma yapabilmesi ve uçuş rotasını takip edebilmesi için kullanılan temel bileşenlerdir. GPS en yaygın kullanılan konum belirleme sensörüdür ve İHA'nın enlem, boylam ve yükseklik bilgilerini sürekli olarak güncelleyerek stabil uçuş sağlar. Bunun yanı sıra, diferansiyel GPS (DGPS) ve gerçek zamanlı kinematik (RTK) gibi gelişmiş GPS sistemleri, daha yüksek konum doğruluğu sağlayarak hassas iniş ve görev planlamalarına katkıda bulunmaktadır.

Görsel algılama sensörleri, kamera ve lazer tabanlı sistemlerden oluşmaktadır. Optik kameralar, görüntü işleme teknikleri ile nesne algılama, arazi haritalama ve engel tespiti için kullanılmaktadır. Lidar (Işık Algılama ve Menzil Belirleme) sensörleri, lazer ışınları kullanarak çevredeki nesnelerin mesafelerini ve konumlarını hassas bir şekilde belirleyerek haritalama ve çarpışma önleme sistemlerinde kritik bir rol oynar. Bu sensörler, özellikle otonom navigasyon sistemlerinde engellerden kaçınma ve yol bulma süreçlerinde büyük önem taşımaktadır.

Sensörlerin entegrasyonu, İHA'nın güvenliği ve verimliliği açısından oldukça önemlidir. Modern İHA sistemlerinde, birden fazla sensörden gelen veriler birleşik bir şekilde işlenerek daha güvenilir ve doğru uçuş kontrolleri sağlanmaktadır. Sensör verilerinin doğru bir şekilde yorumlanması, uçuş kontrol algoritmalarının hassasiyetini artırarak İHA'nın stabilitesini ve manevra kabiliyetini geliştirmektedir.

4.2. Çalışmada Kullanılan Deney Düzeneği

Bu tez çalışması kapsamında, gerçek zamanlı veri toplama, titreşim analizi, uçuş kararlılığı ve veri temelli durum izleme süreçlerinin gerçekleştirilmesine yönelik çok bileşenli bir İHA platformu geliştirilmiştir (Şekil 31). Geliştirilen sistem, yapısal dayanım, enerji verimliliği, stabil uçuş performansı ve güvenilir veri iletişimi kriterleri göz önünde bulundurularak tasarlanmıştır. İHA platformunun oluşturulmasında; gövde, motor, elektronik hız kontrol ünitesi (ESC), batarya, pervane, uçuş kontrol kartı, telemetri sistemi, GPS modülü, kumanda sistemi ve gerçek zamanlı veri toplama altyapısı entegre bir yapı içerisinde değerlendirilmiştir.



Şekil 31. Çalışmada Kullanılan İHA

İHA platformunun mekanik altyapısında, yüksek mukavemet ve düşük ağırlık avantajı sağlaması amacıyla MARK4 V3 Pro 15 Inch 680 mm T8 karbon fiber gövde kullanılmıştır. Karbon fiber malzeme yapısı sayesinde gövde üzerinde oluşan titreşimlerin belirli seviyelerde sönümlenmesi sağlanmış, aynı zamanda uçuş sırasında yapısal rijitlik korunarak daha stabil bir uçuş performansı elde edilmiştir. Hafif gövde yapısı, enerji tüketiminin azaltılmasına katkı sağlarken, sistemin taşıma kapasitesinin artırılmasına da olanak tanımıştır.

İtki sistemi kapsamında, yüksek tork kapasitesi ve enerji verimliliği sağlayan GEPRC EM4218 350KV fırçasız motorlar tercih edilmiştir. Motorlara entegre şekilde çalışan HQProp 15 inç pervaneler sayesinde yüksek kaldırma kuvveti elde edilmiş ve düşük titreşim seviyelerinde kararlı uçuş performansı sağlanmıştır. Motor kontrol süreçlerinde ise GEPRC 4IN1 ESC kullanılmış olup, bu yapı sayesinde motorlar

arasında senkronize güç dağılımı gerçekleştirilerek uçuş stabilitesi artırılmıştır. Ayrıca 4'ü 1 arada ESC yapısı, kablolama karmaşıklığını azaltarak sistemin daha kompakt ve hafif hale gelmesine katkı sunmuştur.

İHA'nın enerji ihtiyacını karşılamak amacıyla 6S 16000 mAh Li-Po batarya kullanılmıştır. Yüksek kapasiteye sahip bu batarya sistemi, motorlar, uçuş kontrol kartı ve veri toplama bileşenlerine kararlı enerji sağlayarak uzun süreli operasyonel görevlerin gerçekleştirilmesine olanak tanımaktadır. Batarya sistemi, yüksek akım gereksinimlerini karşılayabilecek şekilde ESC ve motor altyapısı ile uyumlu olarak yapılandırılmıştır.

Uçuş kontrol süreçlerinde, sensör verilerinin hızlı işlenmesi ve stabil uçuş performansının sağlanması amacıyla SpeedyBee F405 uçuş kontrol kartı tercih edilmiştir. Uçuş kontrol kartı; jiroskop, ivmeölçer ve diğer sensörlerden elde edilen verileri gerçek zamanlı olarak işleyerek motor kontrol sistemlerine düşük gecikmeli komut iletimi sağlamaktadır.

Navigasyon ve konumlandırma işlemlerinde ise Readytosky Ublox NEO M8N GPS modülü kullanılmıştır. GPS sistemi sayesinde İHA'nın konum, hız ve irtifa bilgileri hassas şekilde elde edilmekte ve otonom uçuş süreçlerinde güvenilir navigasyon altyapısı sağlanmaktadır. Ayrıca GPS modülü, uçuş sırasında rota takibi ve konum doğrulama işlemlerinin gerçekleştirilmesine katkıda bulunmaktadır.


Yer kontrol istasyonu ile haberleşme süreçlerinde SIYI alıcı-verici telemetri sistemi kullanılmıştır. Bu sistem sayesinde uçuş verileri gerçek zamanlı olarak yer kontrol istasyonuna aktarılabilmekte ve operatör tarafından anlık takip gerçekleştirilebilmektedir. Telemetri sistemi ile entegre çalışan SIYI MK15 kumanda sistemi ise düşük gecikmeli veri iletimi sağlayarak uçuş sırasında hassas kontrol gerçekleştirilmesine olanak tanımaktadır. Böylece operatör, uçuş parametrelerini gerçek zamanlı olarak izleyebilmekte ve gerektiğinde sisteme müdahale edebilmektedir.

Şekil 31'de gösterilen dört rotorlu multikopter platformu, tez kapsamında yürütülen tüm titreşim ölçümlerinde test düzeneği olarak kullanılmıştır. Her iki yaklaşımda da titreşim verisi, gövdenin ağırlık merkezine (G noktası) yerleştirilen bir Analog Devices ADXL345 üç eksenli ivmeölçer ile ölçülmüş ve bir ESP32 mikrodenetleyicisi aracılığıyla okunmuştur. Ağırlık merkezi yerleşimi, dört rotor tarafından yapısal olarak iletilen titreşimlerin dengeli ve temsil edici bir izini

yakalamakta; ayrıca çoklu sensör dizilerinin yük kapasitesini zorladığı küçük İHA'larda maliyet-etkin, minimalist bir yapısal sağlık izleme senaryosunu temsil etmektedir.


Pervane kaynaklı arızalar, kanatlar üzerinde bilinen konum ve şiddetlerde kontrollü olarak oluşturulmuştur. Benimsenen arıza enjeksiyon yaklaşımı tersinirdir; kalıcı hasar vermeden, yabancı cisim yapışması, döküntü birikmesi, yüzey aşınması ve kısmi kanat kaybı gibi servis içi bozulma etkilerini kalibre edilmiş biçimde taklit eder. Radyal konum, merkezkaç kuvvetinin ($F_c = m r \omega^2$) dönme eksenine olan uzaklıkla ölçeklenmesi nedeniyle arıza şiddetini doğrudan etkileyen kritik bir değişkendir; aynı kütle bozucu, köke yakın bir konuma kıyasla uca yakın uygulandığında daha büyük bir dengesizlik kuvveti üretir. Tez kapsamındaki iki tamamlayıcı yaklaşım, aynı platform ve aynı kontrollü ortam üzerinde, ancak farklı arıza konfigürasyon kümeleri ve veri toplama parametreleriyle değerlendirilmiştir; bu iki deney tasarımı aşağıda ayrı ayrı tanıtılmaktadır.

Birinci yaklaşımda (klasik makine öğrenmesi) yedi pervane konfigürasyonu (Şekil 32) test edilmiştir: bir adet sağlıklı (referans) pervane (Şekil 26) ve şiddeti değişen, kontrollü olarak arızalandırılmış altı pervane. Hasar modları, kanatlar üzerindeki bilinen konumlara kontrollü kütle-bozucu uygulamalarıyla oluşturulmuş; tek kanatta uç kütlesi eklemelerinden asimetrik orta-kanat bozulmalarına ve üç kanada simetrik dağıtılmış uç kütlelerine kadar geniş bir dengesizlik yelpazesini kapsamaktadır. Her uçuş, üç ardışık 60 saniyelik fazdan oluşan standart 180 saniyelik bir protokole tabi tutulmuştur: havada asılı kalma fazında (0–60 s) İHA sabit yükseklikte tutulmuş, manevra fazında (60–120 s) kontrollü yatış, yunuslama ve öteleme girdileri uygulanmış, sert uçuş fazında (120–180 s) ise bilinçli olarak agresif kumanda girdileri verilmiştir. Bu çok fazlı tasarım, arıza tespit edilebilirliğinin farklı operasyonel rejimler altında değerlendirilmesine olanak sağlar.




Şekil 32. Birinci Yaklaşımda Kullanılan Arıza Konfigürasyonu

İkinci yaklaşımda (denetimsiz derin öğrenme) daha sistematik bir arıza enjeksiyon protokolü uygulanmıştır. Pervane kanadı boyunca uçtan köke doğru A (uç), B (orta) ve C (kök) olmak üzere üç radyal konum tanımlanmış; üç arıza mekanizması bu konumlarda farklı şiddetlerde oluşturulmuştur (Şekil 33). Kütle dengesizliği A, B ve C konumlarında 5, 10 ve 15 katman bant ile; yüzey aşınması kanat kalınlığının %25, %50 ve %75'i derinliğinde çizik ile; şiddetli yapısal arıza ise her radyal konumda kanadın tam kesilmesiyle sağlanmıştır. Tüm senaryolarda her deneyde yalnızca tek bir arıza tipi ve tek bir şiddet seviyesi bulundurularak bozulma mekanizması sağlanmıştır. Toplamda 23 farklı konfigürasyon (2 sağlıklı temel + 9 bant + 9 çizik + 3 tam kesim) her biri üç kez tekrar edilerek test edilmiş ve 69 uçuş kaydı elde edilmiştir. Her deney, gaz komutunun 10 saniyelik adımlarla %10'dan %100'e %10'luk basamaklarla artırıldığı ve her seviyenin 40 saniye tutulduğu kademeli bir gaz profiline (toplam 400 s) tabi tutulmuştur. Şekil 34'te, ikinci yaklaşım kapsamında pervane arızalarının sınıflandırılması amacıyla oluşturulan farklı arıza konfigürasyonları sunulmaktadır. Bu kapsamda, pervane üzerinde belirlenen farklı bölgelerde yapay arızalar uygulanarak sağlıklı ve arızalı çalışma durumlarının karşılaştırılması hedeflenmiştir.



Şekil 33. Pervane Üzerinde Uygulanan Kontrollü Yapısal Modifikasyonların Radyal Konumları.




Şekil 34. İkinci Yaklaşımda Kullanılan Arıza Konfigürasyonu (A) A Konumunda Uygulanan Bant Kaynaklı Kütle Dengesizliği; (B) B Konumunda Uygulanan Çizik Hatası; (C) C Konumunda Uygulanan Tam Kesimim ve (D) Sağlıklı Pervane Konfigürasyonu.

Her iki yaklaşıma özgü sensör örnekleme hızı, veri iletim yolu ve sinyal işleme adımları, ilgili oldukları yöntemle birlikte ele alınabilmesi için Bölüm 5'teki alt bölümlerde ayrıntılandırılmıştır. Ölçüm altyapısının donanımsal omurgasını oluşturan gerçek zamanlı veri toplama mimarisi ise her iki yaklaşım için ortak olduğundan Bölüm 4.3'te ele alınmıştır.

4.3. Gerçek Zamanlı Veri Toplama


İHA operasyonel verimliliğini ve güvenliğini artırmak amacıyla, uçuş sırasında gerçek zamanlı veri toplama sistemleri büyük önem taşımaktadır. Uçuş esnasında çeşitli sensörlerden alınan verilerin anlık olarak kaydedilmesi ve analiz edilmesi, sistemin performansını değerlendirmek ve olası anormallikleri tespit etmek açısından kritik bir süreçtir. Bu tez çalışması kapsamında, İHA'ya entegre edilen harici titreşim sensörleri aracılığıyla farklı operasyonel senaryolar ve arıza durumlarını içeren uçuşlar sırasında ham sensör verileri toplanacaktır.

ADXL345 ivmeölçer sensörleri yer almaktadır (Şekil 35). ADXL345 sensörleri, üç eksenli yüksek hassasiyetli ivme ölçümü gerçekleştirebilen dijital sensörler olup, yapısal titreşimlerin analiz edilmesi ve mekanik davranışların izlenmesi açısından kritik öneme sahiptir. Bu sensörler sayesinde uçuş sırasında motor, pervane ve gövde üzerinde oluşan dinamik titreşimler anlık olarak ölçülmekte ve sistemin mekanik bütünlüğüne ilişkin sürekli veri akışı sağlanmaktadır. Sensörlerden elde edilen titreşim verileri, özellikle yapısal sağlık izleme, anomali tespiti ve arıza oluşumlarının erken belirlenmesi açısından önemli bir veri altyapısı oluşturmaktadır.



Şekil 35. Veri Toplama Sisteminde Kullanılan Sensörler

Veri toplama ve veri iletim süreçleri, ESP32 mikrodenetleyici kartı aracılığıyla gerçekleştirilmektedir (Şekil 36). ESP32, yüksek işlem kapasitesi, düşük enerji tüketimi ve kablosuz haberleşme yetenekleri sayesinde gerçek zamanlı veri toplama uygulamalarında yaygın olarak tercih edilen bir mikrodenetleyici platformudur. ADXL345 sensöründen alınan üç eksenli titreşim verileri, İHA'nın ağırlık merkezi (G noktası) bölgesine yerleştirilen sensör mimarisi (Şekil 37) üzerinden ESP32 tarafından belirli örnekleme frekanslarında okunmakta ve eş zamanlı olarak bilgisayar ortamına aktarılmaktadır.




Şekil 36. ESP32 Tabanlı Kablosuz Veri Toplama Mimarisi ve ADXL345 İvmeölçerinin Yerleştirilmesi

Sensörün ağırlık merkezine konumlandırılması sayesinde uçuş sırasında gövde genelinde oluşan titreşim karakteristikleri daha dengeli ve temsil edilebilir şekilde ölçülebilmektedir. Bu yapı sayesinde, uçuş sırasında meydana gelen fiziksel titreşim değişimleri yüksek zaman çözünürlüğü ile takip edilebilmektedir.



Şekil 37. Sensör Setinin İHA Üzerine Yerleştirilmesi

Sensörlerden elde edilen ham veriler, veri bütünlüğünün artırılması amacıyla ön işleme süreçlerinden geçirilmektedir. Bu süreç kapsamında ölçüm verilerindeki ani sapmaların azaltılması, gürültü bileşenlerinin filtrelenmesi ve verilerin analiz edilebilir formata dönüştürülmesi hedeflenmektedir. Özellikle titreşim tabanlı ölçümlerde oluşabilecek çevresel etkiler ve sinyal bozulmaları dikkate alınarak veri stabilizasyonu sağlanmaktadır. Böylece elde edilen ölçüm çıktıları, daha güvenilir analizlerin gerçekleştirilmesine olanak tanımaktadır.



Şekil 38. MATLAB Üzerinden Anlık Veri Takibi

ESP32 üzerinden elde edilen veriler, seri haberleşme altyapısı aracılığıyla MATLAB ortamına gerçek zamanlı olarak aktarılmaktadır (Şekil 38). MATLAB tarafında geliştirilen veri izleme arayüzü sayesinde sensör verileri eş zamanlı olarak okunmakta, görselleştirilmekte, grafiksel döküm haline getirilmekte ve kayıt altına alınmaktadır. MATLAB içerisinde tanımlanan seri haberleşme yapıları kullanılarak ESP32'den gelen veriler anlık olarak işlenmekte ve zaman tabanlı veri akışı sürekli şekilde takip edilmektedir. Aynı zamanda elde edilen veriler belirlenen dosya formatlarında (.txt, .csv vb.) otomatik olarak kaydedilmekte ve ilerleyen analiz süreçleri için arşivlenmektedir. Şekil 39'da verilen kod sayesinde hem çevrim içi (online) hem de çevrim dışı (offline) veri analizi süreçleri etkin biçimde yürütülebilmektedir.

<pre> clear; clc; close all; % --- Ayarlar --- port = "COM...."; baudrate = 115200; try s = serialport(port, baudrate); configureTerminator(s, "LF"); flush(s); disp(" Seri port bağlandı"); catch error(' Porta bağlanılamadı!'); end % Veri t_data = []; x_data = []; y_data = []; z_data = []; listeVerileri = {}; % Durum isPaused = false; pauseStart = 0; totalPausedTime = 0; % --- ARAYÜZ --- fig = figure('Name','İvme Kayıt Sistemi', ... 'Units','normalized', ... 'Position',[0.1 0.1 0.85 0.65]); % Grafik (kalın çizgiler) subplot('Position',[0.05 0.1 0.6 0.8]); h1 = animatedline('Color','r','LineWidth',2,'DisplayName','X'); h2 = animatedline('Color','g','LineWidth',2,'DisplayName','Y'); h3 = animatedline('Color','b','LineWidth',2,'DisplayName','Z'); grid on; legend; % Liste lstBox = uicontrol('Style','listbox', ... 'Units','normalized', ... 'Position',[0.68 0.3 0.30 0.6], ... 'FontSize',10, ... 'FontWeight','bold'); % Pause </pre>	<pre> if ~isPaused if s.NumBytesAvailable > 0 data = readline(s); nums = regexp(data, '[-+]?[d*\.]?[d+]', 'match'); if length(nums) >= 3 t = toc - totalPausedTime; cx = str2double(nums{1}); cy = str2double(nums{2}); cz = str2double(nums{3}); % Veri kaydet t_data(end+1) = t; x_data(end+1) = cx; y_data(end+1) = cy; z_data(end+1) = cz; % Grafik addpoints(h1,t,cx); addpoints(h2,t,cy); addpoints(h3,t,cz); % Liste yeniSatir = sprintf("[%1fs] X:%.2f Y:%.2f Z:%.2f", t,cx,cy,cz); listeVerileri = [{yeniSatir}; listeVerileri]; if length(listeVerileri) > 20 listeVerileri = listeVerileri(1:20); end set(lstBox,'String',listeVerileri); drawnow limitrate; end end else drawnow; end pause(0.01); end % --- EXCEL KAYIT (APPEND) --- disp(" Kayıt yapılıyor..."); </pre>
---	--

<pre> uicontrol('Style','pushbutton', ... 'String',' Pause', ... 'Units','normalized', ... 'Position',[0.68 0.2 0.14 0.07], ... 'FontSize',12, ... 'Callback', @(~,~) pauseFunc(true)); % Resume uicontrol('Style','pushbutton', ... 'String',' Resume', ... 'Units','normalized', ... 'Position',[0.84 0.2 0.14 0.07], ... 'FontSize',12, ... 'Callback', @(~,~) pauseFunc(false)); % Durum yazısı statusText = uicontrol('Style','text', ... 'String','RUNNING', ... 'Units','normalized', ... 'Position',[0.68 0.1 0.30 0.05], ... 'ForegroundColor','g', ... 'FontSize',14, ... 'FontWeight','bold'); disp(" Veri akıyor..."); tic; % --- ANA DÖNGÜ --- while true if ~ishandle(fig) disp(" Grafik kapatıldı"); break; end </pre>	<pre> if ~isempty(t_data) T = table(t_data, x_data, y_data, z_data, ... 'VariableNames', {'Zaman','X','Y','Z'}); dosya = 'kayit.xlsx'; if isfile(dosya) eskiT = readtable(dosya); T = [eskiT; T]; % üzerine ekleme end writetable(T, dosya); disp(" Kaydedildi:"); disp(fullfile(pwd,dosya)); else disp(" Veri yok!"); end delete(s); clear s; % --- PAUSE FONKSİYONU --- function pauseFunc(val) isPaused = evalin('base','isPaused'); totalPausedTime = evalin('base','totalPausedTime'); pauseStart = evalin('base','pauseStart'); statusText = findobj('Style','text'); if val assignin('base','pauseStart',toc); assignin('base','isPaused',true); set(statusText,'String','PAUSED','ForegroundColor','r'); else elapsedPause = toc - pauseStart; totalPausedTime = totalPausedTime + elapsedPause; assignin('base','totalPausedTime',totalPausedTime); assignin('base','isPaused',false); set(statusText,'String','RUNNING','ForegroundColor','g'); end end </pre>
--	--

Şekil 39. MATLAB Kodu

MATLAB ortamında alınan titreşim verileri; istatistiksel analizler, zaman domeni incelemeleri, frekans analizleri ve görselleştirme işlemlerine tabi tutulmaktadır. Gerçek zamanlı grafikler sayesinde titreşim davranışları anlık olarak gözlemlenebilmekte, sistem üzerinde meydana gelen olağan dışı değişimler hızlı şekilde tespit edilebilmektedir. Bunun yanında veri kayıt altyapısı sayesinde uzun süreli titreşim davranışlarının incelenmesi, trend analizlerinin gerçekleştirilmesi ve makine öğrenmesi tabanlı değerlendirme süreçleri için uygun veri kümeleri oluşturulabilmektedir.

Bu bütünleşik yapı, İHA sistemlerinde gerçek zamanlı durum izleme yaklaşımının uygulanabilmesini mümkün hâle getirmektedir. Sensörlerden elde edilen verilerin sürekli olarak takip edilmesi, sistem performansının değerlendirilmesi ve

kritik titreşim davranışlarının erken aşamada belirlenmesi açısından önemli avantajlar sunmaktadır. Özellikle öngörücü bakım uygulamalarında kullanılabilecek veri altyapısının oluşturulması, sistem güvenilirliğinin artırılması ve bakım maliyetlerinin azaltılması açısından büyük önem taşımaktadır.

Gerçek zamanlı veri toplama sistemleri yalnızca uçuş güvenliği açısından değil, aynı zamanda operasyonel sürdürülebilirlik ve bakım optimizasyonu açısından da kritik rol oynamaktadır. Kaydedilen titreşim verileri, ilerleyen aşamalarda makine öğrenmesi ve büyük veri analizi yöntemleri ile değerlendirilerek arıza tahmini, KFÖ analizi ve erken uyarı sistemlerinin geliştirilmesinde kullanılabilecektir. Bu süreç, İHA platformlarının operasyonel verimliliğini artırırken aynı zamanda bakım planlamalarının daha etkin şekilde yapılmasına katkı sağlamaktadır.

Bunun yanı sıra, veri toplama sürecinde kullanılan sistemlerin düşük enerji tüketimine sahip olması ve hafif donanım yapısı sunması, İHA performansı açısından önemli avantaj oluşturmaktadır. ESP32 tabanlı veri toplama mimarisi, kompakt yapısı ve yüksek veri işleme kapasitesi sayesinde gerçek zamanlı uygulamalar için uygun bir altyapı sunmaktadır. Gerçek zamanlı veri aktarımı ve eş zamanlı veri kaydı sayesinde sistemin izlenebilirliği artırılmakta ve veri kayıpları minimize edilmektedir.


Sonuç olarak, bu tez çalışması kapsamında kullanılan ADXL345 sensörleri, ESP32 mikrodenetleyici altyapısı ve MATLAB tabanlı gerçek zamanlı veri işleme sistemi; titreşim verilerinin anlık olarak toplanması, analiz edilmesi ve kayıt altına alınması açısından bütünsel bir mühendislik çözümü sunmaktadır. Geliştirilen bu yapı, İHA sistemlerinde durum izleme, arıza tespiti ve öngörücü bakım uygulamalarının gerçekleştirilebilmesi adına önemli bir altyapı oluşturmaktadır. Gerçek zamanlı veri analizi süreçlerinin geliştirilmesi ve sistem entegrasyonunun ilerletilmesi, gelecekte daha güvenilir, akıllı ve sürdürülebilir İHA sistemlerinin geliştirilmesine katkı sağlayacaktır.

5. ÇALIŞMADA KULLANILAN YÖNTEM

Pervane arızalarının titreşim verisinden tespiti bu tezde iki yöntemle ele alınmıştır. Birinci yöntem, titreşim sinyallerinden çıkarılan istatistiksel özniteliklere dayalı klasik makine öğrenmesi sınıflandırıcılarını kullanır. İkinci yöntem ise sinyalin zaman–frekans temsilleri üzerinde çalışan denetimsiz bir derin öğrenme modelidir. İki yöntem de Bölüm 4'te tanıtılan platformdan ve deney düzeneğinden elde edilen verilerle, aynı analiz ortamında (MATLAB R2024b) uygulanmıştır. Bu sayede iki yöntemin sonuçları aynı veri tabanı üzerinde doğrudan karşılaştırılabilmektedir.

5.1. Birinci Yaklaşım: Klasik Makine Öğrenmesi ile Pervane Arıza Sınıflandırması

Birinci yöntem, Bölüm 4.2'de tanıtılan yedi pervane konfigürasyonundan (bir sağlıklı referans ve altı kontrollü arıza) ve üç fazlı uçuş protokolünden (Şekil 40) elde edilen titreşim kayıtlarını sınıflandırır. Titreşim verisi, gövdenin ağırlık merkezine (G noktası) yerleştirilen dijital bir ivmeölçer ile ölçülmüştür. Hedeflenen yapısal kusurlar (statik dengesizlik, hücum kenarı kıymıkları, asimetrik kanat incilmesi) titreşimde düşük dereceli genlik modülasyonları üretir; bu modülasyonlar standart sapma, tepe-tepe, RMS ve yüksek dereceli istatistiksel momentler gibi öznitelikler aracılığıyla izlenebilir. Ham titreşim kaydında altı arıza iki genlik grubuna ayrılır. Arıza-1, Arıza-4 ve Arıza-6 yüksek genlikli ve geniş dağılımlı imzalar üretir; Arıza-2, Arıza-3 ve Arıza-5 ise sağlıklı referansla örtüşen düşük genlikli imzalar üretir ve bu nedenle ayırt edilmeleri güçtür.



Şekil 40. Üç Fazlı Uçuş Protokolünün Zaman Çizelgesi (Havada Asılı Kalma, Manevra ve Sert Uçuş Fazları).

5.1.1. Veri Ön İşleme ve Öznitelik Çıkarımı

Ham ivme verileri sensör başlatma kalıntıları ve aykırı değerler içerdiğinden, öznitelik çıkarımından önce ön işleme tabi tutulmuştur. Her eksen için çeyrekler arası aralık (Interquartile Range, IQR) yöntemiyle bağımsız bir aykırı değer eleme uygulanmıştır. Her eksen a için IQR, üçüncü ve birinci çeyrekler ($Q_{3,a}$, $Q_{1,a}$) arasındaki farktır ve veri noktaları yalnızca aşağıdaki koşulu sağladığında korunmuştur:

$$Q_{1,a} - k \cdot IQR_a \leq x_a \leq Q_{3,a} + k \cdot IQR_a \quad (7)$$

Burada $k = 2,0$ alınmıştır. Aykırı değer eleme sonrası silme oranı konfigürasyona göre %2,94 ile %33,45 arasında değişmiş; ardından tüm kayıtlar 0–180 s aralığına kırpılmıştır.

Öznitelikler, 10 saniyelik pencere ve 5 saniyelik örtüşme ile kayar pencere yaklaşımıyla çıkarılmıştır. Her pencerede ve her ekseninde ortalama, standart sapma, karekök ortalama (RMS), tepe-tepe genliği, çarpıklık, basıklık ile en küçük ve en büyük değerler hesaplanmıştır. Bunlara ek olarak vektörel titreşim büyüklüğü $M = \sqrt{x_X^2 + x_Y^2 + x_Z^2}$ ile bu büyüklüğün ortalama, standart sapma ve RMS değerleri öznitelik vektörüne eklenmiştir. Böylece her pencere için 27 öznitelik (8 öznitelik $\times$ 3 eksen + 3 büyüklük özniteliği) elde edilmiş ve tüm konfigürasyonlardan toplam 180 öznitelik vektörü üretilmiştir.

5.1.2. Kullanılan Makine Öğrenmesi Yöntemleri

Çalışmada, öznitelik vektörlerini sınıflandırmak için literatürde yaygın olarak kullanılan dört denetimli makine öğrenmesi yöntemi —Rastgele Orman, Destek Vektör Makinesi, k-En Yakın Komşu ve Karar Ağacı— değerlendirilmiştir. Öznitelikler sınıflandırmadan önce z-puanı ile normalleştirilmiş; veri kümesi, sınıf oranları korunarak %70 eğitim ve %30 test olacak biçimde ayrılmış, genelleme başarımı tüm veri kümesi üzerinde 5-katlı tabakalı çapraz doğrulama ile de ölçülmüştür. Sınıflandırma hem ikili (sağlıklı/arızalı) hem de yedi sınıflı görev için yürütülmüş; her görevde doğruluk, hassasiyet, anma ve F1-skoru hesaplanmıştır.

Kullanılan yöntemlerin kuramsal temelleri ve karar kuralları aşağıdaki alt başlıklarda açıklanmıştır.

5.1.2.1. Rastgele Orman (Random Forest, RF)

Rastgele Orman, çok sayıda karar ağacını bir araya getiren bir topluluk (ensemble) öğrenme yöntemidir. Her ağaç, eğitim kümesinden önyükleme (bootstrap) ile rastgele seçilen bir alt küme üzerinde ve her bölünmede özneliklerin rastgele bir alt kümesi değerlendirilerek yetiştirilir. Bu iki düzeyli rastgelelik, ağaçlar arasındaki ilişkiyi azaltarak topluluğun varyansını düşürür ve tek bir ağaca kıyasla aşırı öğrenmeye karşı daha dayanıklı bir sınıflandırıcı elde edilmesini sağlar. Sınıflandırmada, $B = 100$ ağacın her biri bağımsız bir tahmin üretir ve nihai etiket çoğunluk oyuyla belirlenir:

$$\hat{y} = \arg \max_c \sum_{b=1}^B I(T_b(\mathbf{x}) = c) \quad (8)$$

Burada $T_b(\mathbf{x})$ b. ağacın tahminini, $I(\cdot)$ gösterge fonksiyonunu ve c sınıf etiketini göstermektedir. Yöntem, çok sayıda istatistiksel öznelik arasından ayırt edici olanları örtük biçimde önceliklendirebildiğinden ve gürültüye karşı görece dayanıklı olduğundan, titreşim öznelikleriyle pervane arızalarının sınıflandırılmasında tercih edilmiştir. Ayrıca ağaçların bölünmelerinde özneliklerin kullanım sıklığı, öznelik önem sıralaması olarak yorumlanabilir.

5.1.2.2. Destek Vektör Makinesi (Support Vector Machine, SVM)

Destek Vektör Makinesi, iki sınıfı birbirinden ayıran ve sınıflar arasındaki kenar payını (margin) en büyük yapan karar sınırını arayan bir sınıflandırıcıdır. Karar sınırı yalnızca sınıf sınırına en yakın örnekler (destek vektörleri) tarafından belirlenir; bu da yöntemi, öznelik sayısının görece yüksek olduğu durumlarda etkili kılar. Öznelikler doğrusal olarak ayıramadığında, çekirdek hilesi (kernel trick) ile veriler örtük biçimde daha yüksek boyutlu bir uzaya taşınır; çalışmada, yerel benzerlikleri esnek biçimde modelleyen radyal tabanlı çekirdek (RBF) kullanılmıştır. Karar fonksiyonu ve çekirdek sırasıyla Denklemler 9 ve 10 tanımlanmıştır.

$$f(\mathbf{x}) = \text{sign} \left(\sum_{i=1}^n \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + b \right) \quad (9)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp \left(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2 \right) \quad (10)$$

Burada α ve y sırasıyla destek vektörü katsayılarını ve sınıf etiketlerini, b yanlılık terimini, γ ise çekirdek genişliğini göstermektedir. Düzenleştirme parametresi ile çekirdek genişliği, küçük bir doğrulama kümesi üzerinde ayarlanmıştır. Çok sınıflı görevde sınıflandırma, bire-karşı-bir şemasıyla gerçekleştirilmiştir.

5.1.2.3. k-En Yakın Komşu (k-Nearest Neighbors, KNN)

k-En Yakın Komşu, örnek tabanlı (parametresiz) bir sınıflandırma yöntemidir. Bir test örneğinin etiketi, öznitelik uzayında kendisine en yakın k komşusunun sınıflarına bakılarak belirlenir; eğitim aşamasında açık bir model kurulmaz, sınıflandırma doğrudan örnekler arası uzaklıklar üzerinden yapılır. Komşuluk ilişkisi Öklid uzaklığıyla Denklem 11’de tanımlanmıştır:

$$d(\mathbf{x}_i, \mathbf{x}_j) = \sqrt{\sum_{m=1}^p (x_{i,m} - x_{j,m})^2} \quad (11)$$

Burada p öznitelik sayısını göstermektedir. Test örneği, en yakın $k = 5$ komşusunun çoğunluk sınıfına atanır. Yöntemin başarımı uzaklık ölçeğine duyarlı olduğundan öznitelikler sınıflandırmadan önce normalleştirilmiş; küçük k değerleri yerel örüntülere duyarlılığı artırırken gürültüye karşı dayanıklılığı azalttığından, k değeri deneysel olarak seçilmiştir.

5.1.2.4. Karar Ağacı (Decision Tree, DT)

Karar Ağacı, öznitelik uzayını ardışık ikili kurallarla bölerek hiyerarşik bir sınıflandırma yapısı kuran, yorumlanabilirliği yüksek bir yöntemdir. Her düğümde, alt kümelerin sınıf saflığını en çok artıran öznitelik ve eşik değeri seçilir; saflık, Gini safsızlığı ölçütüyle Denklem 12’de değerlendirilir.

$$G(t) = 1 - \sum_{c=1}^C p_{c|t}^2 \quad (12)$$

Burada $p(c|t)$, t düğümünde c sınıfına ait örneklerin oranını, C ise toplam sınıf sayısını göstermektedir. Her bölünme, bu ölçütteki azalmayı en büyük yapacak biçimde belirlenir ve ağaç, durdurma ölçütleri sağlanana kadar büyütülür. Karar ağacı tek başına aşırı öğrenmeye eğilimli olsa da, Rastgele Orman topluluğunun temel yapı taşını oluşturması ve karar sürecinin doğrudan izlenebilmesi nedeniyle bir temel (baseline) yöntem olarak değerlendirilmiştir.

5.2. İkinci Yaklaşım: Denetimsiz Derin Öğrenme ile Anomali Tespiti

İkinci yöntem, pervane arızalarını denetimsiz biçimde ve erken evrede tespit eden bir derin öğrenme çerçevesidir. Yöntemin iki özgün bileşeni vardır: deneysel olarak ölçülmüş ayrık arıza durumlarından sürekli bir bozulma yörüngesi kuran şiddete göre sıralanmış veri zenginleştirme (Bölüm 5.2.2) ve zaman–frekans örüntüleri ile kısa ve uzun erimli zamansal bağımlılıkları tek bir modelde birleştiren CNN–BiGRU–SSM–AE otoenkoder mimarisi (Bölüm 5.2.3).

Titreşim verisi, birinci yöntemde olduğu gibi gövdenin ağırlık merkezine (G noktası) yerleştirilen ve bir ESP32 mikrodenetleyicisine bağlı dijital bir ivmeölçer ile kaydedilmiştir. Tanımlanan 23 konfigürasyon (2 sağlıklı temel + 9 bant + 9 çizik + 3 tam kesim, toplam 69 uçuş kaydı; Şekiller 33 ve 34) ve kademeli gaz profili bu yöntemin veri kümesini oluşturur. Sağlıklı uçuşların spektral analizine göre rotor temel frekansı gaz komutuyla yaklaşık doğrusal artar; %10 gazda ortalama ~40 Hz iken %100 gazda ~80 Hz'e ulaşır. Rotor dengesizliği uyarımı merkezkaç kuvvetiyle ($F_c \propto m r \omega^2$) ölçeklendiğinden, açısal hızdaki artış harmonik genliğin ve frekans kaymasının fiziksel olarak yorumlanabilir biçimde gözlenmesini sağlar. Bu ilişki, şiddete göre sıralanmış veri zenginleştirmenin fiziksel dayanağını oluşturur.

5.2.1. Sürekli Dalgacık Dönüşümü Tabanlı Zaman–Frekans Temsili

Titreşim sinyalleri kayar pencere yaklaşımıyla bölütlenmiştir. Her segment, 1024 örnek (yaklaşık 1,28 s) uzunluğunda ve 512 örnek (0,64 s) atlamalı örtüşen pencerelere ayrılmıştır. Her pencere, Sürekli Dalgacık Dönüşümü (Continuous

Wavelet Transform, CWT) ile zaman–frekans gösterimine dönüştürülmüştür. Bir pencere için eksen a 'nın CWT'si

$$W_s^{(a)}(f, \tau) = \int x_s^{(a)}(t) \psi_f^*(t - \tau) dt \quad (13)$$

şeklinde tanımlanmıştır; burada $\psi_f(t)$ dalgacık taban fonksiyonunu, $*$ ise karmaşık eşleniği göstermektedir. Skalogram büyüklüğü, sayısal kararlılığı artıran ve dinamik aralığı sıkıştıran logaritmik dönüşümle $A_s^{(a)}(f, \tau) = \log(1 + |W_s^{(a)}(f, \tau)|)$ olarak hesaplanmıştır. Elde edilen skalogramlar 48×96 (frekans $\times$ zaman) sabit çözünürlüğe yeniden boyutlandırılmıştır. Bu çözünürlük deneysel olarak seçilmiştir: 48 frekans gözesi ilgili 10–300 Hz bandını yeterli logaritmik çözünürlükle kapsarken, 1,28 s pencere boyunca 96 zaman gözesi yaklaşık 13 ms'lik zamansal çözünürlük sağlamaktadır. Üç eksenenden gelen skalogramlar kanal boyunca yığılarak $48 \times 96 \times 3$ boyutlu birleştirilmiş tensörler oluşturulmuştur. Bu temsil, titreşim enerjisinin hem frekans hem de zaman içindeki dağılımını koruduğundan evrişimli kodlayıcı için uygun bir giriş sağlar.

5.2.2. Şiddete Göre Sıralanmış Veri Zenginleştirme

İHA pervanelerinde gerçek zamanlı sürekli bozulma yörüngesi tek bir kontrollü deneyde kaydedilemez; çünkü hasar, uçuş öncesinde mekanik olarak verilmek zorundadır ve ölçümler ayırık sağlık durumlarına karşılık gelir. Bu sınırlılığını aşmak için, deneysel olarak ölçülmüş uçuş verilerini sistematik biçimde bir araya getirerek zamansal olarak tutarlı bir bozulma dizisini yeniden kuran şiddete göre sıralanmış (severity-ordered) bir veri zenginleştirme çerçevesi geliştirilmiştir (Şekil 39). Yöntemin adımları aşağıda özetlenmiştir.


Önce tüm deneylerin gaz sinyalleri toplanarak küresel en küçük (θ_{min}) ve en büyük (θ_{max}) değerler belirlenmiş ve her gaz sinyali $\theta_{norm} = 100 \cdot (\theta - \theta_{min}) / (\theta_{max} - \theta_{min})$ ifadesiyle 0–100 aralığına ölçeklenmiştir. Normalleştirilmiş gaz, operasyonel rejim hizalamasını sağlamak için 10'ar birimlik ayırık plato seviyelerine yuvarlanmıştır. Her pervane koşulu için tekrarlı uçuşlar birleştirilerek tek bir kayıt oluşturulmuş ve bu kayıt, gaz platosu geçişlerine göre segmentlere ayrılmıştır. Bir segment sınırı, normalleştirilmiş gazdaki mutlak değişimin $|\Delta\theta_{norm}| \geq \delta$ ($\delta = \%1$)

eşliğini aştığı noktada tanımlanmış; geçici kalıntıları elemek için 5 saniyeden kısa segmentler atılmıştır. Her gaz platosu içinde titreşim şiddeti, dayanıklı bir tepe-tepe metriğiyle

$$S = P_{97,5}(x) - P_{2,5}(x) \quad (14)$$

şeklinde hesaplanmıştır; burada $P_{97,5}$ ve $P_{2,5}$ titreşim genliği dağılımının 97,5. ve 2,5. yüzdelik dilimleridir. Bu metrik, darbe niteliğindeki aykırı değerlere karşı duyarlılığı azaltırken dengesizlik ve yapısal süreksizliklerle ilişkili genlik büyümesini korur. Çıkarılan segmentler önce titreşim şiddetine (birincil ölçüt, $S \uparrow$), ardından gaz seviyesine (ikincil ölçüt, $\theta \uparrow$) göre artan sırada sıralanmış ve ardışık olarak birleştirilerek her eksen için sürekli bir zenginleştirilmiş seri elde edilmiştir.

İki düzeyli sıralamanın fiziksel temeli rotor dinamiğine dayanır. Merkezkaç dengesizlik kuvveti $F_c = m r \omega^2$ ilişkisi gereği, bir defektin büyümesi (kütlenin m artması veya radyal konum r 'nin değişmesi) herhangi bir rotor hızında titreşim genliğini monotonik olarak artırır; gaz artışı ise ω 'yı yükselterek aynı dengesizlik kuvvetini kuadratik olarak büyütür. Bu nedenle birincil sıralama segmentleri defekt-büyüme eksenini boyunca dizerken, ikincil sıralama benzer şiddetteki segmentleri artan aerodinamik yüke göre düzenler. Önemli bir nokta, bu stratejinin veriyi yapay olarak çoğaltmamasıdır; zenginleştirilmiş dizideki her segment kontrollü koşullarda yürütülen gerçek deneylerden gelir. "Zenginleştirme" burada ölçülmüş segmentlerin şiddete göre yeniden sıralanması ve birleştirilmesi anlamına gelir, sentetik veri üretimi değil. Ayrıca dayanıklı tepe-tepe metriği yalnızca sıralama ölçütüdür; anomali tespit özneliliğinin kendisi değildir. Çıktı olarak eksen başına yaklaşık 7,5 saatlik sürekli bir titreşim yörüngesi elde edilmiştir. Şekil 41'de şiddete göre sıralanmış veri zenginleştirme algoritmasının temel işlem adımları gösterilmektedir. Akış şeması, veri setindeki arıza örneklerinin şiddet düzeylerine göre düzenlenmesini ve sınıflandırma modelinin eğitiminde kullanılmak üzere zenginleştirilmesini özetlemektedir.




Şekil 41. Şiddete Göre Sıralanmış Veri Zenginleştirme Algoritmasının Akış Şeması.

5.2.3. CNN–BiGRU–SSM–AE Mimarisi

Zenginleştirilmiş üç eksenli titreşim verileri üzerinde anormal titreşim örüntülerini belirlemek için denetimsiz bir derin öğrenme tabanlı anomali tespit çerçevesi geliştirilmiştir (Şekil 40). Önerilen model, yalnızca sağlıklı İHA titreşim dinamiklerinin manifoldunu öğrenip anomalileri yeniden yapılandırma hatası üzerinden tespit eden, üç eksenli kaynaştırılmış zaman–frekans dizi otoenkoderidir. Mimarinin tasarımındaki temel ilke, titreşim verisinin barındırdığı farklı bilgi türlerinin her birinin özelleşmiş bir bileşenle ele alınmasıdır: yerel zaman–frekans örüntüleri evrimsel katmanlarla, kısa erimli zamansal bağımlılıklar çift yönlü tekrarlayan birimlerle, uzun erimli dinamikler durum-uzay bloğuyla ve operasyonel rejim değişimi gaz farkındalıklı koşullandırma ile modellenir. Bileşenlerin her birinin katkısı Bölüm 6.2.6'daki ablasyon çalışmasıyla nicel olarak doğrulanmıştır. Mimari, kodlayıcı–zamansal model–kod çözücü olmak üzere üç aşamalıdır ve aşağıdaki alt

bölümlerde ayrıntılandırılmıştır. Şekil 42’de, CNN–BiGRU–SSM–AE hibrit otoenkoder mimarisinin temel blok yapısı sunulmaktadır.



Şekil 42. CNN–BiGRU–SSM–AE Hibrit Otoenkoder Mimarisinin Blok Diyagramı.

5.2.3.1. Evrişimli Kodlayıcı (CNN)

Giriş, $48 \times 96 \times 3$ boyutlu zaman–frekans skalogram tensörüdür; bu temsil, görüntü benzeri uzamsal-spektral örüntüler içerdiğinden evrişimli işleme doğal olarak uygundur. Kodlayıcı, stride-2 alt örnekleme uygulayan üç evrişim katmanından oluşur ve giriş skalogramlarını kademeli olarak sıkıştırır. Küresel uzamsal havuzlamayı izleyen tam bağlantılı bir katman, her zaman penceresinin titreşim durumunu özetleyen 192 boyutlu bir gizli vektör üretir. Böylece evrişimli kodlayıcı, harmonik bantlar, yapısal rezonanslar ve geniş bantlı enerji yayılımı gibi ayırt edici zaman–frekans özniteliklerini el yapımı öznitelik mühendisliğine gerek kalmadan otomatik olarak çıkarır.

5.2.3.2. Gaz Farkındalıklı Koşullandırma

Titreşim genliği, herhangi bir yapısal arıza olmasa dahi yalnızca rotor hızına (gaz seviyesine) bağlı olarak belirgin biçimde değişir; merkezkaç kuvvetinin açışal hızın karesiyle ölçeklenmesi nedeniyle, yüksek gazdaki normal bir titreşim artışı, modele bilgi verilmediğinde bir arıza gibi algılanabilir ve yanlış alarmlara yol açar. Bu sorunu gidermek için, her segmentte kaydedilen gaz yüzdesi ayrı bir koşullandırma yolundan geçirilir: skaler gaz değeri küçük bir tam bağlantılı katmandan geçirilerek gizli kod ile aynı boyutta bir koşullandırma vektörüne yansıtılır ve zamansal modelleme aşamalarından önce CNN gizli vektörüne eleman bazında eklenir. Bu tasarım, ağıın iç temsilini mevcut operasyonel rejime göre ayarlamasını ve normal gaz değişimlerinin yarattığı genlik değişimlerini yapısal bozulmadan kaynaklananlardan ayırt etmesini sağlayarak değişen rotor hızlarında yanlış alarmları azaltır.

5.2.3.3. BiGRU ile Zamansal Modelleme

Titreşim segmentleri zaman içinde evrilen bir dizi oluşturduğundan, ardışık pencereler arasındaki bağımlılıkların modellenmesi gerekir. Bu amaçla çift yönlü kapılı tekrarlayan birim (Bidirectional Gated Recurrent Unit, BiGRU) kullanılmıştır. BiGRU, diziyi hem ileri hem geri yönde işleyerek her zaman adımının temsiline geçmiş ve gelecek bağlamı katar; böylece arızaların yol açtığı geçici örüntüler ve zarf değişimleri daha güçlü biçimde yakalanır.

5.2.3.4. SSM Durum-Uzayı Bloğu

BiGRU kısa ve orta erimli bağımlılıkları yakalamakta etkin olsa da, uzun bir bozulma yörüngesi boyunca biriken yavaş değişimlerin modellenmesinde verimliliği sınırlıdır. Bu nedenle, Mamba mimarisinden esinlenen kapılı bir durum-uzay modeli (State-Space Model, SSM) bloğu eklenmiştir. SSM, gizli bir durumu zaman adımları boyunca evrimleştirerek uzun erimli zamansal dinamikleri doğrusal hesaplama karmaşıklığıyla verimli biçimde modeller. Bölüm 6.2.6'daki ablasyon sonuçları, bu bloğun yalnızca tespit duyarlılığını artırmakla kalmayıp, BiGRU'nun tek başına yol açtığı aşırı duyarlılığı (yüksek yanlış alarm oranını) dengeleyerek daha kararlı bir gizli temsil öğrenilmesini sağladığını göstermektedir.

5.2.3.5. Kod Çözücü ve Kayıp Fonksiyonu

Kod çözücü (decoder), transpoze evrişim katmanlarıyla gizli temsili $48 \times 96 \times 3$ boyutlu skalograma yeniden inşa eder. Ağ, yalnızca sağlıklı titreşim segmentleri kullanılarak öz-denetimli (self-supervised) biçimde eğitilmiştir. Zenginleştirilmiş seri şiddet metriğine göre sıralandığından, en düşük şiddetli alt %20 segment normal çalışma koşullarının temsilcisi olarak kabul edilmiştir. Bu eşik, sıralı dizinin iki sağlıklı temel konfigürasyonla başlaması nedeniyle seçilmiş; %20 sınırının temel kayıtları ilk arıza enjekte edilmiş koşullardan (en dış konumda 5 katlı bant) ayıran doğal bir sınır oluşturduğu doğrulanmıştır. Ağ parametreleri, gradyan kırpma ile Adam optimizatörü kullanılarak eniyilenmiş; eğitim hedefi, maskelenmiş ortalama mutlak yeniden yapılandırma hatasını en aza indirmektir.

5.2.4. Anomali Skorlama ve Eşikleme

Eğitimin ardından her titreşim segmenti için yeniden yapılandırma hatasına dayalı bir anomali skoru hesaplanır. Karar eşiği (τ), eğitim setindeki yeniden yapılandırma hatalarının 99. yüzdalık diliminden (P_{99}) belirlenmiştir. Yüzdelik tabanlı bu eşikleme, beklenen yanlış alarm oranını denetlerken Gauss olmayan hata dağılımlarına karşı dayanıklı kaldığından denetimsiz anomali tespitinde yaygın olarak kullanılır. Anomali skoru τ eşiğini aşan segmentler, olası bir itki sistemi arızasına işaret edecek biçimde anormal olarak işaretlenir.

Önerilen mimarinin başarımı, aynı zenginleştirilmiş veri kümesi ve aynı eğitim protokolü altında üç yaygın denetimsiz yöntemle karşılaştırılmıştır: izolasyon ormanı (Isolation Forest), tek sınıflı destek vektör makinesi (One-Class SVM) ve LSTM otoenkoder (LSTM-AE). Ayrıca her mimari bileşeninin katkısını incelemek için CNN-AE, CNN-BiGRU-AE ve tam CNN-BiGRU-SSM-AE modellerinin değerlendirildiği aşamalı bir ablasyon çalışması yürütülmüştür.

5.3. Değerlendirme Metrikleri

Sınıflandırma başarımı için doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall), F1-skoru ve karmaşıklık matrisi kullanılmıştır. Doğruluk, doğru sınıflandırılan pencerelerin oranını; hassasiyet ve duyarlılık sırasıyla pozitif tahminlerin güvenilirliğini ve gerçek pozitiflerin yakalanma oranını ölçer. F1-skoru, hassasiyet ile duyarlılık harmonik ortalamasıdır ve sınıf dengesizliği bulunan

durumlarda daha dengeli bir ölçüt sağlar. Ablasyon çalışmasında ise eğitim, test ve tüm veri için ortalama anomali skoru, anomali işaretleme oranı (flag rate) ve karar eşiği (P_{99}) raporlanmıştır.

6. BULGULAR VE TARTIŞMA

Bu bölümde, geliştirilen iki tamamlayıcı yöntemsel yaklaşımın deneysel sonuçları sırasıyla sunulmaktadır. Önce klasik makine öğrenmesi ile elde edilen sınıflandırma bulguları, ardından denetimsiz derin öğrenme tabanlı anomali tespit performansı ele alınmaktadır.

6.1. Klasik Makine Öğrenmesi Tabanlı Sınıflandırma Bulguları

6.1.1. Titreşim Karakteristikleri


Yedi pervane konfigürasyonu için Y-ekseni ivme verisinin istatistiksel özeti Tablo 4'te sunulmuştur. Sağlıklı pervane, Y-ekseninde en düşük titreşim standart sapmasını ($3,55 \text{ m/s}^2$) sergilemektedir. Buna karşın Arıza-4 ve Arıza-6, ciddi yapısal kusurları yansıtacak şekilde 25 m/s^2 'nin üzerinde standart sapma ve 100 m/s^2 'nin üzerinde tepe-tepe genliği üretmektedir. Arıza-2, Arıza-3 ve Arıza-5 ise sağlıklı tabana göre çok daha ince titreşim sapmaları göstermektedir; bu durum, basit genlik analizinin bu tür hafif kusurları ayırt etmekte yetersiz kaldığını ortaya koymaktadır.

Tablo 4. Yedi Konfigürasyon için Y-Eksen İvme Verisi İstatistiksel Özeti (m/s^2)


Pervane	Ortalama	Standart Sapma	Tepe-Tepe	Basıklık
Sağlıklı	-1,64	3,55	20,24	-0,21
Arıza-1	-1,35	17,17	134,19	-0,50
Arıza-2	-2,75	2,52	19,06	1,91
Arıza-3	-1,66	2,85	18,75	2,76
Arıza-4	-1,10	25,69	109,05	-0,96
Arıza-5	-1,42	2,64	17,42	-0,16
Arıza-6	-0,41	25,64	139,65	-0,16

Zaman serisi ivme verileri, sağlıklı pervanenin tüm fazlarda kararlı ve düşük genlikli titreşim sergilediğini; arızalı pervanelerin ise belirgin yüksek genlikli ve düzensiz osilasyonlar ürettiğini doğrulamaktadır. Eksen bazında kutu grafikleri, Arıza-1, Arıza-4 ve Arıza-6 için geniş dağılımları, Arıza-2, Arıza-3 ve Arıza-5 için ise daha ince sapmaları göstermektedir. Uçuş fazlarına göre titreşim büyüklüğü RMS karşılaştırması önemli bir gözlem ortaya çıkarmıştır: titreşim genlikleri genellikle havada asılı kalmadan sert uçuşa doğru artmakta; ancak sağlıklı/arızalı kontrastı en belirgin biçimde havada asılı kalma fazında görülmektedir. Bu durum, durağan rejimin arıza kaynaklı titreşimleri maskeleymeden açığa çıkardığını göstermektedir. Şekil 43'te,

yedi farklı pervane konfigürasyonu için üç eksenle ölçülen temsili ivme zaman serileri gösterilmektedir. Şekil 44'te, pervane konfigürasyonlarına göre X, Y ve Z eksenlerindeki ivme dağılımları kutu grafiği ile verilmiştir. Bu grafik, farklı arıza durumlarının eksen bazlı titreşim seviyeleri üzerindeki etkisini özetlemektedir.




Şekil 43. Yedi Pervane Konfigürasyonu İçin Temsili Üç Eksenli İvme Zaman Serileri.



Şekil 44. Pervane Konfigürasyonlarına Göre Eksen Bazında İvme Dağılımlarının Kutu Grafiği.

Şekil 45'te, farklı uçuş fazlarına göre RMS ivme genlikleri karşılaştırılmaktadır. Grafik, uçuş sürecinde titreşim seviyelerinin fazlara bağlı olarak nasıl değiştiğini ve arıza durumlarının bu değişim üzerindeki etkisini özetlemektedir.



Şekil 45. Uçuş Fazlarına Göre RMS İvme Genliğinin Karşılaştırılması.

6.1.2. Çoklu Sınıf Sınıflandırma Sonuçları

Yedi sınıflı arıza sınıflandırması için bekletilen (held-out) test kümesi üzerindeki karşılaştırmalı sonuçlar Tablo 5'te sunulmuştur. Rastgele Orman sınıflandırıcısı %83,33 doğruluk ve 0,8156 F1-skoru ile en iyi genel performansı sergilemiş; bunu Karar Ağacı (%81,48), KNN (%75,93) ve SVM (%70,37) izlemiştir. Rastgele Orman için elde edilen karmaşıklık matrisi, yanlış sınıflandırmaların düşük genlikli arızalar (özellikle Arıza-2 ve Arıza-3) arasında yoğunlaştığını; yüksek genlikli arızaların (Arıza-1, Arıza-4, Arıza-6) ise birbirleriyle veya sağlıklı sınıfla neredeyse hiç karışmadığını göstermektedir.

Tablo 5. Çoklu Sınıf Sınıflandırma Sonuçları (Yedi Sınıf, %30 Test Kümesi)

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F1
Rastgele Orman	0,8333	0,8175	0,8333	0,8156
Karar Ağacı	0,8148	0,8031	0,8148	0,7988
KNN	0,7593	0,7766	0,7593	0,7357
SVM	0,7037	0,6575	0,7037	0,6676


Sınıf bazında ayrıntılı başarımlar Tablo 6'da verilmiştir. Sağlıklı sınıf ve yüksek genlikli arızalar güçlü hassasiyet ve duyarlılık değerleriyle geri kazanılmakta (Arıza-4 hem hassasiyet hem duyarlılıkta 1,0'a, Arıza-1 ise %77 hassasiyette tam duyarlılığa ulaşmaktadır); düşük genlikli arızalar ise artık hatanın neredeyse tamamını oluşturmaktadır. Arıza-2'nin hiç geri kazanılamaması (test bölünmesinde hassasiyet ve duyarlılık sıfır olması) öncelikle bir örnek-sayısı kısıtıdır: tüm veri kümesinde yalnızca yedi Arıza-2 penceresi bulunmakta, bunlardan ikisi test kümesine düşmektedir. Bu nedenle makro-ortalama F1 (0,72), ağırlıklı F1'e (0,82) kıyasla yüksek genlikli sınıfların kolaylığını olduğundan az, azınlık sınıflarının zorluğunu ise olduğundan fazla yansıtmakta; iki ortalama birlikte okunmalıdır.

Tablo 6. Rastgele Orman Sınıflandırıcısının Yedi Sınıflı Bazında Başarımı


Sınıf	Hassasiyet	Duyarlılık	F1	Destek
Sağlıklı	0,7273	0,8000	0,7619	10
Arıza-1	0,7692	1,0000	0,8696	10
Arıza-2	0,0000	0,0000	0,0000	2
Arıza-3	0,7500	0,7500	0,7500	4
Arıza-4	1,0000	1,0000	1,0000	10
Arıza-5	0,8182	0,9000	0,8571	10
Arıza-6	1,0000	0,6250	0,7692	8
Makro ort.	0,7235	0,7250	0,7154	54
Ağırlıklı ort.	0,8175	0,8333	0,8156	54

Rastgele Orman'ın Gini saflık azalmasına dayalı öznitelik önem sıralaması, ayırt edici gücün genlik-dağılımı betimleyicilerinde toplandığını ortaya koymaktadır. Baskın öznitelik Y-ekseni RMS'i (0,086) olup; bunu Z-ekseni en küçük değeri (0,081), Y-ekseni standart sapması (0,063), X-ekseni tepe-tepe genliği (0,062) ve Y-ekseni en büyük değeri (0,058) izlemektedir. Yüksek dereceli momentler (çarpıklık ve basıklık) sıralamanın alt sıralarında yer almakta; üç eksenin ortalamaları ise neredeyse hiç ayırt edici ağırlık taşımamaktadır. Bu durum, izleme görevi için dağılım-merkezi yerine genlik-dağılımı tabanlı bir öznitelik kümesinin kullanılmasını desteklemektedir.

Şekil 46'da, Rastgele Orman sınıflandırıcısının yedi pervane konfigürasyonu için elde ettiği sınıflandırma sonuçları karmaşıklık matrisi ile gösterilmektedir. Şekil 47'de, Rastgele Orman modeline göre sınıflandırmada en etkili olan 15 özneliğin önem sıralaması sunulmaktadır. Bu grafik, arıza türlerini ayırt etmede hangi özneliklerin daha belirleyici olduğunu göstermektedir.



Şekil 46. Rastgele Orman Sınıflandırıcısının Yedi Sınıflı Karmaşıklık Matrisi.



Şekil 47. Rastgele Orman Modeline Göre En Ayırt Edici 15 Özniteliğin Önem Sıralaması.

6.1.3. İkili Sınıflandırma Sonuçları

Pratik açıdan en önemli görev olan ikili (sağlıklı/arızalı) tespit için tüm sınıflandırıcılar belirgin biçimde daha yüksek doğruluk göstermiştir (Tablo 7). Rastgele Orman %94,44 doğruluk ile en yüksek başarıyı yakalamış ve gerçek zamanlı

güvenlik izleme uygulamaları için yüksek güvenilirlik düzeyine ulaşmıştır. Çoklu sınıftan ikili göreve geçişte tüm sınıflandırıcılarda yaklaşık 11 puanlık bir iyileşme görülmektedir; "bir şeylerin yanlış olduğu" bilgisi, hangi kusurun bulunduğu bilgisine kıyasla veriden çok daha kolay çıkarılabilmektedir.

Tablo 7. İkili Sınıflandırma Sonuçları (Sağlıklı vs. Arızalı, %30 Test Kümesi)

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F1
Rastgele Orman	0,9444	0,9432	0,9444	0,9433
Karar Ağacı	0,9259	0,9259	0,9259	0,9259
KNN	0,8704	0,8658	0,8704	0,8677
SVM	0,8148	0,6639	0,8148	0,7317

6.1.4. Çapraz Doğrulama Kararlılığı


Tek bir bölünmeden elde edilen bekletilen skorlar küçük veri kümelerinde yanıltıcı olabileceğinden, 5-katlı tabakalı çapraz doğrulama sonuçları Tablo 8'de raporlanmıştır. Rastgele Orman çoklu sınıf görevinde $0,911 \pm 0,021$, ikili görevde ise $0,956 \pm 0,028$ değerine ulaşmıştır. Standart sapmaların yeterince küçük olması, sınıflandırıcılar arasındaki sıralamanın katmanlar boyunca kararlı kaldığını göstermektedir. SVM en düşük başarıyı sergilemiş; bunun temel nedeni, sınırlı veri kümesi boyutu ile 27 boyutlu öznitelik uzayının birleşimidir; RBF çekirdekli SVM'lerin gerektirdiği C ve γ ince ayarı 180 örneklik bir veri kümesinde yeterince desteklenememektedir.

Tablo 8. 5-Katlı Tabakalı Çapraz Doğrulama Sonuçları (Ortalama $\pm$ Standart Sapma)


Sınıflandırıcı	Çoklu Sınıf ÇD	İkili ÇD
Rastgele Orman	$0,911 \pm 0,021$	$0,956 \pm 0,028$
Karar Ağacı	$0,889 \pm 0,018$	$0,928 \pm 0,042$
KNN	$0,783 \pm 0,044$	$0,861 \pm 0,047$
SVM	$0,778 \pm 0,050$	$0,811 \pm 0,011$

İkili ile çoklu sınıf başarımları arasındaki belirgin fark, arıza tespitinin yüksek güvenilirlikle yapılabildiğini, ancak kesin arıza tipi tanımlamasının daha zengin öznitelik temsilleri ve daha fazla veri gerektirdiğini göstermektedir. Sınıf dağılımındaki dengesizlik (Arıza-2: 7 örnek; Sağlıklı: 34 örnek) çoklu sınıf görevinde temel kısıttır; bu dengesizliğe SMOTE gibi sentetik aşırı örnekleme yerine, her arıza koşulu için ek bağımsız uçuşlar toplanarak yaklaşılması daha sağlıklı bir çözüm olarak değerlendirilmektedir. Rastgele Orman, bu dengesizliğe rağmen iyi bir genel başarımla korumuştur.

Şekil 48’de dört klasik sınıflandırıcının ikili ve çoklu sınıf sınıflandırma görevlerindeki test doğrulukları karşılaştırılmaktadır. Şekil 49’da, 5-katlı tabakalı çapraz doğrulama sonucunda sınıflandırıcı doğruluklarının ortalama ve standart sapma değerleri verilmiştir. Bu sonuçlar, modellerin genel başarısını ve performans kararlılığını göstermektedir.



Şekil 48. Dört Klasik Sınıflandırıcının İkili ve Çoklu Sınıf Görevlerdeki Test Doğruluğu Karşılaştırması.




Şekil 49. 5-Katlı Tabakalı Çapraz Doğrulamada Sınıflandırıcı Doğruluklarının Ortalama ve Standart Sapması.

6.2. Denetimsiz Derin Öğrenme Tabanlı Anomali Tespit Bulguları

6.2.1. Sağlıklı Temel Davranışı


Sağlıklı pervane konfigürasyonunda kademeli gaz uyarımı altında titreşim genliğinin tüm üç eksende monotonik biçimde arttığı gözlemlenmiştir. Zaman–frekans gösterimleri iki baskın spektral bileşeni ortaya çıkarmaktadır: yaklaşık 35–45 Hz'de tüm gaz seviyelerinde yatay olarak sabit kalan yapısal mod (değişmeyen sertlik ve simetrik kütle dağılımının işareti) ile gaz arttıkça spektral genliği artan 60–140 Hz arası rotor harmonik bandı. Tam gazda rotor bandı genliği yaklaşık –15 ile –20 dB'ye ulaşırken 200 Hz üstündeki geniş bant içeriği –35 dB altında kalmıştır; bu, sağlıklı pervanenin dar bantlı, harmonik baskın dinamiğini doğrulamaktadır. Şekil 50'de, sağlıklı pervanenin kademeli gaz profili altındaki zaman alanı ve zaman–frekans gösterimi sunulmaktadır. Grafik, gaz seviyesindeki değişime bağlı olarak titreşim sinyalinin genlik ve frekans özelliklerindeki değişimi özetlemektedir.



Şekil 50. Sağlıklı Pervanenin Kademeli Gaz Profili Altında Zaman ve Zaman–Frekans Gösterimi.

6.2.2. Şiddetli Yapısal Arıza

C konumunda tam kesim arızası altında ölçülen veriler, sağlıklı duruma kıyasla belirgin farklılıklar göstermiştir. İlk gaz adımlarında (0–100 s) belirgin geçici patlamalar ve kararlı durumda zarf düzensizlikleri gözlemlenmiştir. Spektral enerji, sağlıklı durumdaki 60–140 Hz bandından yaklaşık 40–180 Hz aralığına yayılmakta ve spektral genlik baz durumdaki ≈ -15 dB'den ≈ 0 dB'ye yükselmektedir (yaklaşık +15 dB güç artışı). Güç spektral yoğunluğu (PSD) karşılaştırması tüm pervane koşullarını üç ekseninde karakterize etmiştir: bant kaynaklı dengesizlik temel harmonik genliğini artırmakta ancak spektral bant genişliğini önemli ölçüde değiştirmemekte; çizik arızaları (%25–75) orta düzeyde harmonik genişleme ve 80–150 Hz arası enerji artışı üretmekte; tam kesim ise geniş bantlı amplifikasyon, 100–200 Hz arası 10–15 dB artış ve harmonik tepenin görünmez hale gelmesine yol açmaktadır. Şekil 51'de, C konumunda oluşturulan tam kesim arızasına ait titreşim sinyalinin zaman alanı ve zaman–frekans gösterimi sunulmaktadır.




Şekil 51. Tam Kesim (C Konumu) Arızasının Zaman ve Zaman–Frekans Gösterimi.


6.2.3. Temel Frekans ve RMS Eğilimleri

Sağlıklı konfigürasyonlar X-ekseninde gaz arttıkça doğrusal frekans artışı sergilemektedir (%20 gazda ≈ 40 –45 Hz, %100 gazda ≈ 140 –150 Hz). Bant kaynaklı dengesizlik ve düşük şiddetli çizikler bu doğrusallığı korurken, şiddetli kesim


durumlarında yüksek gazda ani frekans düşüşleri ($\approx 25\text{--}30\text{ Hz}$) gözlemlenmektedir. Bu düşüşler gerçek bir rotor hızı sıçramasını değil, temel frekans takip algoritmasının en yüksek spektral tepeyi hedeflemesi nedeniyle şiddetli hasarda $1\times$ rotor harmoniğinin baskınlığını yitirip yapısal rezonanslara veya geniş bant gürültüye kaymasını yansıtmaktadır; bu, harmonik kararlılığın kaybının ayırt edici bir göstergesidir. RMS ivme eğrileri, sağlıklı koşullarda RMS'in $1,5\text{--}3\text{ m/s}^2$ aralığında kaldığını, orta şiddetli arızaların 4 m/s^2 altında seyrettiğini, ancak tam kesim durumlarında X-ekseninde RMS'in $10\text{--}11\text{ m/s}^2$ 'yi aşarak baz duruma göre üç katın üzerine çıktığını göstermektedir. Şekil 52'de, tüm pervane koşullarına ait güç spektral yoğunluğu değerleri karşılaştırılmaktadır. Grafik, sağlıklı ve arızalı pervanelerin frekans alanındaki titreşim davranışlarını özetlemektedir. Şekil 53'te, gaz konumuna bağlı olarak temel dönme frekansının değişimi gösterilmektedir. Şekil 54'te, gaz konumuna göre RMS ivme genliğindeki değişim sunulmaktadır. Grafik, farklı gaz seviyelerinde titreşim şiddetinin nasıl değiştiğini göstermektedir.



Şekil 52. Tüm Pervane Koşulları İçin Güç Spektral Yoğunluğu (PSD) Karşılaştırması.



Şekil 53. Gaz Konumuna Göre Temel Dönme Frekansının Değişimi.



Şekil 54. Gaz Konumuna Göre RMS İvme Genliğinin Değişimi.

6.2.4. Şiddete Göre Sıralanmış Zenginleştirilmiş Veri

Erken segmentler (sağlıklı + düşük şiddet) dar genlik bantları sergilerken, çizik arızalarının başlangıcıyla orta düzey büyüme görülmektedir. Belirgin bir bulgu, bant kaynaklı dengesizliğin kesim arızalarına yakın genlikler üretmesidir; bu, kütle yeniden dağılımının periyodik uyarımı güçlü biçimde artırması ile açıklanmaktadır. Zaman–frekans spektrogramları zenginleştirilmiş seri boyunca monoton spektral evrimi ortaya koymaktadır: ilk saatte 0–100 Hz baskın ve ≈ 50 Hz'de kararlı harmonik

The figure consists of three subplots showing acceleration (Titreşim) in m/s^2 over time (Zaman) in hours (h) for different building models and damage levels. The subplots are titled 'X ekseninden elde edilen veriler', 'Y ekseninden elde edilen veriler', and 'Z ekseninden elde edilen veriler'.

The X-axis for all plots is 'Zaman (h)' ranging from 0 to 8. The Y-axis for all plots is 'Titreşim (m/s^2)' ranging from -30 to 30.

The legend identifies the following data series:

- Sağlıklı 1 (Healthy 1)
- Sağlıklı 2 (Healthy 2)
- A Konumunda 5 Katmanlı Bant (5-story band in position A)
- A Konumunda 10 Katmanlı Bant (10-story band in position A)
- A Konumunda 15 Katmanlı Bant (15-story band in position A)
- C Konumunda 5 Katmanlı Bant (5-story band in position C)
- C Konumunda 10 Katmanlı Bant (10-story band in position C)
- C Konumunda 15 Katmanlı Bant (15-story band in position C)
- B Konumunda %25 Çizik Hatası (25% crack error in position B)
- C Konumunda %25 Çizik Hatası (25% crack error in position C)
- A Konumunda %50 Çizik Hatası (50% crack error in position A)
- B Konumunda %50 Çizik Hatası (50% crack error in position B)
- A Konumunda %75 Çizik Hatası (75% crack error in position A)
- B Konumunda %75 Çizik Hatası (75% crack error in position B)
- A Konumunda Kesildi (Cut in position A)
- B Konumunda Kesildi (Cut in position B)
- C Konumunda Kesildi (Cut in position C)

114

6.2.5. Anomali Tespit Performansı Karşılaştırması

Dört yöntemin niceliksel performansı Tablo 9'da karşılaştırılmıştır. Önerilen CNN-BiGRU-SSM-AE mimarisi tüm metriklerde en yüksek performansı sergilemiştir. İzolasyon Ormanı, aşırı aykırı değerleri tespit edebilmesine rağmen titreşim sinyallerindeki ince zamansal örüntüleri yakalamakta zorlanmış ($F1 = 0,1886$; $AUROC = 0,7215$); Tek Sınıflı SVM bir miktar iyileşme sağlamış ($F1 = 0,2308$; $AUROC = 0,7579$) ancak açık zamansal modelleme yokluğu nedeniyle sınırlı kalmıştır. LSTM-AE, ardışık bağımlılıkları modelleyerek klasik yöntemlere göre belirgin bir iyileşme göstermiştir ($F1 = 0,4630$; $AUROC = 0,9027$). Önerilen CNN-BiGRU-SSM-AE ise 0,9959 hassasiyet, 0,4428 duyarlılık, 0,6131 F1-skoru ve 0,9284 AUROC ile tüm metriklerde en iyi sonucu vermiştir. Bu üstünlük, mimari bileşenlerin tamamlayıcı rollerine atfedilebilir: evrişimli kodlayıcı CWT skalogramlarından ayırt edici zaman-frekans özniteliklerini çıkarmakta, çift yönlü GRU zamansal bağımlılıkları her iki yönde yakalamakta, durum uzayı modülü uzun erimli zamansal dinamikleri modellemekte ve gaz farkındalıklı koşullandırma operasyonel rejim değişimini bozulmadan ayırt ederek yanlış pozitifleri azaltmaktadır.


Tablo 9. Anomali Tespit Performansının Niceliksel Karşılaştırması

Model	Hassasiyet	Duyarlılık	F1	AUROC
İzolasyon Ormanı	0,9812	0,1043	0,1886	0,7215
Tek Sınıflı SVM	0,9863	0,1307	0,2308	0,7579
LSTM-AE	0,9921	0,3014	0,4630	0,9027
CNN-BiGRU-SSM-AE	0,9959	0,4428	0,6131	0,9284

Literatürdeki güncel İHA anomali tespit çalışmalarıyla niteliksel bir karşılaştırma Tablo 10'da sunulmuştur. Mevcut çalışmaların büyük çoğunluğu (Chen vd., 2024; Jeon vd., 2023; Jung vd., 2024; Fang vd., 2025; Jasra vd., 2025) arızaları ayırık durumlar olarak ele almakta ve sağlıklıdan bozulmuş geçişi modellememektedir. Buna karşın, önerilen çerçeve eğitim için sürekli bir bozulma dizisi kullanmakta; model, ayırık arıza örüntülerini ezberlemek yerine aşamalı bozulmanın spektral evrimini öğrenmektedir. Bu nedenle, bu yaklaşım, ayırık arıza kategorileri arasına düşen erken evre sapmaların tespitini mümkün kılmaktadır. Şekil 57'de, dört farklı anomali tespit yönteminin başarımlarına göre karşılaştırmalı sonuçları sunulmaktadır.

Tablo 10. Güncel Döner Kanat İHA Anomali Tespit Yöntemleriyle Karşılaştırma

Çalışma	Yöntem	Giriş Türü	Arıza Modellemesi
Chen vd.(2024)	Conv-AE + SVDD	Uçuş parametreleri	Ayrık
Jeon vd. (2023)	LSTM-AE	Titreşim	Ayrık
Jung vd. (2024)	SR3 + LSTM-AE	Titreşim (düşük örnekleme)	Ayrık
Fang vd. (2025)	DSC-AE	Çoklu sistem	Ayrık
Jasra vd. (2025)	LSTM/GRU/CNN/Transformer	Uçuş verisi	Ayrık
Önerilen	CNN-BiGRU-SSM-AE	3D CWT titreşim	Sürekli

**Şekil 57.** Dört Anomali Tespit Yönteminin Başarım Metriklerine Göre Karşılaştırması.

6.2.6. Ablasyon Çalışması

Mimari bileşenlerin ayrı ayrı katkısını anlamak için üç aşamalı bir ablasyon çalışması yürütülmüştür (Tablo 11). CNN-AE temel modeli (yalnızca evrişimli kodlama/kod çözme) en tutucu davranışı sergilemiş; tüm segmentlerin %15,24'ünü, test segmentlerinin ise %18,84'ünü anormal olarak işaretlemiştir. Zamansal modelleme eksikliği, evrim gösteren arızaları yakalama yeteneğini sınırlamaktadır. CNN-BiGRU-AE eklenmesiyle anomali duyarlılığı belirgin biçimde artmış (işaretleme oranı tüm/test: %35,56 / %44,20), ancak model operasyonel varyasyonlara karşı aşırı duyarlı hale gelmiştir. Önerilen CNN-BiGRU-SSM-AE, durum uzayı modellemesi ve gaz koşullandırması ile dengeli bir davranış sağlamış (işaretleme oranı %22,27 / %27,54); en yüksek P_{99} eşliğini (0,6314) üretmesi, normal operasyonun beklenen titreşim varyasyonlarına karşı daha az duyarlı bir gizli temsil öğrenildiğini göstermektedir.

Tablo 11. Ablasyon Çalışması Sonuçları

Model	Eşik (P_{99})	İşaretleme (Tüm)	İşaretleme (Test)	Ort. Skor (Tüm)	Ort. Skor (Eğitim)	Ort. Skor (Test)
CNN-AE	0,6242	0,1524	0,1884	0,5808	0,5384	0,5913
CNN- BiGRU-AE	0,6044	0,3556	0,4420	0,5867	0,5169	0,6041
CNN- BiGRU- SSM-AE	0,6314	0,2227	0,2754	0,5924	0,5349	0,6066

Bu sonuçlar, hem zamansal yapı hem de operasyonel rejim modellemesinin İHA itki sistemleri için güvenilir anomali tespiti açısından birlikte gerekli olduğunu göstermektedir. Eğitim verisinde daha düşük yeniden yapılandırma hatası sağlıklı dinamiklerin daha iyi modellendiğini, daha düşük işaretleme oranı ise yanlış alarm üretme eğiliminin azaldığını göstermektedir.

6.3. Bulguların Genel Değerlendirilmesi

İki yöntem birbirini tamamlar. Birinci yöntem, basit istatistiksel öznitelikler ve klasik sınıflandırıcılarla ikili tespitte %94'ün üzerinde doğruluğa ulaşır; hesaplama yükü düşük olduğundan sınırlı kaynaklı platformlarda da uygulanabilir. İkinci yöntem ise sürekli dalgacık dönüşümü ve hibrit derin mimari sayesinde erken evre anomalileri ve aşamalı bozulma yörüngesini yakalar; AUROC'u 0,93 düzeyine çıkarır. Ablasyon çalışması, yalnızca zamansal modelleme (BiGRU) eklemenin yanlış pozitifleri artırdığını, durum uzayı modeli ve gaz koşullandırması ile birlikte kullanıldığında ise dengeli ve yüksek hassasiyetli bir tespit elde edildiğini gösterir. Adaptif karar eşiği, ham IMU verisine dayalı bir son-işlem düzeltmesi yerine mimarinin yapısal bir parçası olduğunda daha etkilidir.

Literatür açısından değerlendirildiğinde, Bölüm 1'de belirtilen temel boşluklar önemli ölçüde kapatılmıştır. 23 konfigürasyon (sağlıklı + üç arıza tipi $\times$ üç şiddet $\times$ üç radyal konum) ile mevcut çalışmalardaki bir-iki ayrık kategori ötesine geçen geniş bir arıza manifoldu deneysel olarak elde edilmiş; tamamen denetimsiz CNN-BiGRU-SSM-AE, yalnızca %20 düşük şiddetli normal segmentle eğitilerek denetimli yöntemlere yakın AUROC değerlerine ulaşmış; gaz farkındalıklı koşullandırma ise klasik sabit eşikli yaklaşımları aşan adaptif bir tespit performansı sergilemiştir.

7. SONUÇ VE ÖNERİLER

Literatürde yer alan çalışmaların büyük bölümünün yalnızca denetimli sınıflandırma veya yalnızca denetimsiz anomali tespitine odaklanmaktadır. Ayrıca, mevcut çalışmalarda yaygın olarak titreşim verileri kablolu olarak toplanmaktadır. Bu tez çalışmasında, İHA'da pervane kaynaklı yapısal arızaların titreşim verilerinden erken tespiti amacıyla birbirini tamamlayan iki veri temelli yaklaşım geliştirilmiştir. Çalışma kapsamında, ADXL345 ivmeölçer sensöründen elde edilen titreşim verileri, ESP32 Wi-Fi modülü aracılığıyla kablosuz olarak gerçek zamanlı biçimde toplanmış ve kaydedilmiştir. Elde edilen veri setleri üzerinde çevrimdışı (offline) analizler gerçekleştirilerek, ilk yaklaşımda istatistiksel özniteliklere dayalı klasik makine öğrenmesi yöntemleriyle bilinen pervane arızaları başarıyla sınıflandırılmıştır. İkinci yaklaşımda ise, arıza şiddetine göre sıralanmış özgün bir veri zenginleştirme stratejisi geliştirilmiş ve bu yöntemle oluşturulan veri seti kullanılarak CNN-BiGRU-SSM-AE tabanlı hibrit otoenkoder mimarisi ile etiketli veriye ihtiyaç duyulmaksızın erken evre anomalilerin tespiti gerçekleştirilmiştir. Bu bütünleşik yaklaşım sayesinde hem bilinen arızaların tanınması hem de daha önce görülmemiş anomalilerin belirlenmesi tek bir çatı altında ele alınarak İHA'larda veri temelli kestirimci bakım uygulamalarına uygulanabilir ve özgün bir çerçeve sunulmuştur.

7.1. Genel Sonuçlar

Birinci yöntemde, ağırlık merkezine yerleştirilen ivmeölçerden alınan titreşim verisinden 10 saniyelik kayar pencerelerde 27 istatistiksel öznitelik çıkarılmış ve dört klasik sınıflandırıcı ile değerlendirilmiştir. Rastgele Orman sınıflandırıcısı, ikili (sağlıklı/arızalı) görevde %94,44 test doğruluğu ve 5-katlı çapraz doğrulamada %95,6 ortalama doğruluk; yedi sınıflı arıza tanımlamasında ise %83,33 test doğruluğu ve çapraz doğrulamada %91,1 doğruluk ile en yüksek başarıyı sergilemiştir. İkili tespitteki bu yüksek başarı, doğrulama sonrası gerçek zamanlı bir "kalkış noktasına dönüş" karar kuralını destekleme potansiyeline işaret etmektedir. Çoklu sınıf görevdeki sınırlama ise temel olarak sınıflandırıcı seçiminden değil, veri kümesi boyutundan; özellikle düşük genlikli arızalara ait örnek sayısının azlığından kaynaklanmaktadır. Standart sapma, RMS ve tepe-tepe genliği gibi genlik-dağılımı betimleyicileri en ayırt edici öznitelikler olarak öne çıkmış; havada asılı kalma fazı,

durağan rejimin arıza imzasını maskeleyememesi nedeniyle en bilgilendirici uçuş fazı olarak belirlenmiştir.

İkinci yaklaşımda, deneysel olarak ölçülmüş ayırık arıza durumlarından fiziksel olarak tutarlı sürekli bir bozulma yörüngesini yeniden inşa eden, şiddete göre sıralanmış bir veri zenginleştirme stratejisi geliştirilmiştir. Bu strateji, eksen başına yaklaşık 7,5 saatlik sürekli titreşim verisi üreterek geleneksel veri kümelerinde gözlemlenemeyen ara bozulma durumlarını açığa çıkarmıştır. Bu zenginleştirilmiş veri üzerinde eğitilen CNN–BiGRU–SSM–AE hibrit otoenkoder mimarisi; İzolasyon Ormanı, Tek Sınıflı SVM ve LSTM–AE temel modellerini geride bırakarak 0,9959 hassasiyet, 0,4428 duyarlılık, 0,6131 F1-skoru ve 0,9284 AUROC değerlerine ulaşmıştır. Ablasyon çalışması, yalnızca zamansal modelleme (BiGRU) eklemenin yanlış pozitifleri artırdığını; durum uzayı modeli (SSM) ve gaz farkındalıklı koşullandırma ile birlikte kullanıldığında ise dengeli ve yüksek hassasiyetli bir tespit elde edildiğini doğrulamıştır. Bu sonuç, adaptif karar eşiği kavramının, ham ivmeölçer temelli bir düzeltme yerine mimarinin yapısal bir parçası olarak içselleştirildiğinde daha etkin olduğunu göstermektedir.

Her iki yaklaşım birlikte değerlendirildiğinde, tek bir üç eksenli ivmeölçerin titreşim spektrumunda, kontrollü ve farklı şiddetlerdeki yapısal kusurların fiziksel olarak yorumlanabilir, ayırt edici imzalar ürettiği ve bu imzaların hem klasik makine öğrenmesi hem de denetimsiz derin öğrenme yöntemleriyle öğrenilebildiği hipotezi doğrulanmıştır. Çalışmanın özgün metodolojik katkısı, deneysel olarak gözlemlenemeyen sürekli bozulma yörüngesinin şiddete göre sıralı zenginleştirme ile yeniden inşası ve rotor dinamiği bilgisinin derin öğrenme hattına yapısal olarak gömülmesidir.

7.2. Öneriler ve Gelecek Çalışmalar

Çalışma kapsamında tespit edilen sınırlılıklar temelinde aşağıdaki gelecek çalışma yönleri önerilmektedir.

Veri kümesinin genişletilmesi: Çoklu sınıf başarımının temel kısıtı veri hacmidir. Özellikle düşük genlikli arızalar için tek uzun uçuş yerine çok sayıda kısa tekrar uçuşunun toplanması, sınıf dengesizliğinin azaltılması ve sınıflandırıcı güveninin tekrarlı ölçümlerle değerlendirilmesi önerilmektedir.

Çoklu sensör füzyonu: Bu çalışmada yalnızca tek bir ivmeölçerden elde edilen titreşim verileri kullanılmıştır. Gelecek çalışmalarda, titreşim verisinin akım, voltaj, motor devri (RPM), sıcaklık, IMU, GPS, akustik ve diğer uçuş parametreleri ile birlikte değerlendirilmesi önerilmektedir. Bunun yanı sıra, aynı fiziksel büyüklüğü ölçen birden fazla sensörden elde edilen verilerin karşılaştırmalı olarak analiz edilmesi ve sensör doğrulama (sensor redundancy) mekanizmalarının geliştirilmesi önerilmektedir. Bu sayede sensör arızaları ve ölçüm hatalarından kaynaklanabilecek yanlış kararların azaltılması, yapay zekâ tabanlı karar mekanizmalarının daha güvenilir hale getirilmesi ve gerçek zamanlı arıza tespit doğruluğunun artırılması mümkün olabilecektir.

Birim-arası transfer öğrenmesi: Otoenkoderin öğrendiği sağlıklı temel, üretim toleransları, yatak aşınması ve motor yaşlanması nedeniyle teste tabi tutulan birime özgüdür. Modelin farklı İHA birimlerine ve platformlarına minimum yeniden eğitimle aktarılması için alan adaptasyonu ve değişkenlik farkındalıklı eğitim stratejilerinin geliştirilmesi gerekmektedir.

Güncel yapay zekâ mimarileriyle genişletilmiş karşılaştırmalar: Önerilen yöntemin transformer tabanlı otoenkoderler, difüzyon tabanlı anomali tespit modelleri, grafik sinir ağları (GNN) ve diğer güncel derin öğrenme mimarileri ile karşılaştırılması, farklı veri kümeleri üzerindeki performansının değerlendirilmesine katkı sağlayacaktır.

Monotonik olmayan bozulma modellemesi: Şiddete göre sıralı zenginleştirme, merkezkaç kuvvetine dayalı monotonik bir birinci derece yaklaşımdır. Gerçek bozulmanın aralıklı kararlılaşıma veya ani hasar geçişleri gibi monotonik olmayan davranışlarını içeren stokastik sıralama stratejilerinin araştırılması önerilmektedir.

Kalan faydalı ömrün açık entegrasyonu: Erken arıza tespiti ile KFÖ tahmini, kestirimci bakımın birbirini tamamlayan iki temel aşamasıdır. Bu tez kapsamında geliştirilen CNN–BiGRU–SSM–AE tabanlı denetimsiz anomali tespit modeli, İHA sisteminde normal davranıştan sapmanın başladığını erkenden belirlemektedir. KFÖ tahmininde ise İHA'nın sağlık göstergesinin zamana bağlı değişimini modelleyerek bileşenin kritik arıza noktasına ulaşmaya kadar güvenli şekilde çalışabileceği süreyi öngörmektedir. Bu nedenle, gelecek çalışmalarda otoenkoder yeniden yapılandırma hatasının LSTM veya GRU tabanlı zaman bağlı sağlık göstergesi tahmin modelleriyle bütünleştirilmesi ve gerçek uçuş verileri üzerinde doğrulanması, yalnızca anomalilerin

erken tespit edilmesini değil, aynı zamanda KFÖ nicel olarak tahmin edilmesini sağlayarak erken arıza tespiti ve KFÖ tahminini aynı karar destek sistemi içerisinde bütünleşik hale getirecektir.

Gerçek zamanlı gömülü yapay zekâ tabanlı karar sistemi: Eğitilen makine öğrenmesi ve denetimsiz derin öğrenme modellerinin Pixhawk, NVIDIA Jetson, Raspberry Pi veya benzeri gömülü yapay zekâ platformlarına aktarılması ve uçuş sırasında sensör verilerini gerçek zamanlı olarak işleyerek anlık karar verebilen otonom bir karar destek sistemine dönüştürülmesi önerilmektedir. Böylece geliştirilecek sistem; tespit edilen anomali seviyesine göre göreve devam etme, güvenli iniş, acil iniş veya görevi sonlandırma gibi kararları insan müdahalesine gerek duymadan gerçekleştirebilecektir. Bu yaklaşım, görüş hattı dışı (BVLOS) operasyonlar ve gelecekteki otonom İHA sistemleri açısından önemli bir araştırma alanı oluşturmaktadır.

Gerçek zamanlı otonom sağlık izleme sistemi: Geliştirilen modellerin yalnızca çevrimdışı analizlerde değil, gerçek uçuş sırasında sürekli çalışan bir sağlık izleme sistemi olarak uygulanması önerilmektedir. Gerçek zamanlı sensör verilerini sürekli analiz eden, anomali seviyesini dinamik olarak izleyen ve karar mekanizmasını uçuş boyunca güncelleyebilen bir yapay zekâ altyapısının geliştirilmesi, tam otonom kestirimci bakım sistemlerinin oluşturulmasına katkı sağlayacaktır.

Farklı İHA platformlarında doğrulama: Bu çalışmada geliştirilen yöntem yalnızca döner kanatlı bir multikopter platformunda doğrulanmıştır. Gelecek çalışmalarda yöntemin quadcopter, hexacopter, octocopter, sabit kanatlı ve hibrit İHA platformlarında farklı motor, pervane ve uçuş profilleri altında test edilmesi önerilmektedir. Ayrıca farklı görev senaryoları, taşıma kapasiteleri ve çevresel koşullar altında gerçekleştirilecek deneylerle modelin genelleme yeteneği, sağlamlığı ve farklı platformlara aktarılabilirliği kapsamlı olarak değerlendirilmelidir.

Genişletilmiş açık ortam saha kampanyaları: Farklı rüzgâr şiddetleri, türbülans, sıcaklık ve nem koşullarını kapsayan çok mevsimli gerçek uçuş deneylerinin gerçekleştirilmesi ve çevresel değişkenlerin model performansına etkisinin niceliksel olarak incelenmesi önerilmektedir.

Sonuç olarak, bu tez İHA pervane sağlığı izleme alanında klasik makine öğrenmesi ve denetimsiz derin öğrenme yaklaşımlarını aynı çatı altında birleştirerek erken arıza tespiti için uygulanabilir bir yöntem ortaya koymuştur. Gerçek zamanlı veri

toplama altyapısı, tek sensör tabanlı düşük maliyetli yaklaşımı ve kontrollü deneylerden oluşturulan özgün veri kümesi ile geliştirilen yöntem, İHA'larda kestirimci bakım uygulamaları için önemli bir temel oluşturmaktadır. Gelecekte çoklu sensör füzyonu, gömülü yapay zekâ tabanlı gerçek zamanlı karar mekanizmaları ve farklı İHA platformlarında gerçekleştirilecek doğrulama çalışmaları ile bu yaklaşımın tam otonom sağlık izleme ve akıllı uçuş yönetim sistemlerine dönüştürülebileceği değerlendirilmektedir.

KAYNAKÇA

- Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., ... & Zhou, L. (2023). Drones in plant disease assessment, efficient monitoring, and detection: A way forward to smart agriculture. *Agronomy*, 13(6), 1524.
- Abualsauod, E. H. (2022). A hybrid blockchain method in internet of things for privacy and security in unmanned aerial vehicles network. *Computers and Electrical Engineering*, 99, 107847.
- Adadi, A. (2021). Büyük veri çağında veri açısından verimli algoritmalar üzerine bir araştırma. *Büyük Veri Dergisi*, 8 (1), 24.
- Agarwal, A., Mohanta, C., & Mehta, S. N. (2023). Drone Technologies: State-of-the-Art, Challenges, and Future Scope. *Drone Technology: Future Trends and Practical Applications*, 1-19.
- Aibin, M., Aldiab, M., Bhavsar, R., Lodhra, J., Reyes, M., Rezaeian, F., ... & Taer, M. (2021). Survey of RPAS autonomous control systems using artificial intelligence. *IEEE Access*, 9, 167580-167591.
- Alharbi, A., Petrunin, I., & Panagiotakopoulos, D. (2023). Deep learning architecture for UAV traffic-density prediction. *Drones*, 7(2), 78.
- Altinors, A., Yol, F., & Yaman, O. (2021). A sound-based method for fault detection with statistical feature extraction in UAV motors. *Applied Acoustics*, 183, 108325.
- Aşcı, B. (2024). The Historical Roots of Air Intelligence (AIRINT): Terminology Development Attempt. *International Journal of Intelligence and CounterIntelligence*, 1-22.
- Bai, M., Yang, W., Song, D., Kosuda, M., Szabo, S., Lipovsky, P., & Kasaei, A. (2020). Research on energy management of hybrid unmanned aerial vehicles to improve energy-saving and emission reduction performance. *International Journal of Environmental Research and Public Health*, 17(8), 2917.
- Balestrieri, E., Daponte, P., De Vito, L., Picariello, F., & Tudosa, I. (2021). Sensors and measurements for UAV safety: An overview. *Sensors*, 21(24), 8253.
- Bershadsky, D., Haviland, S., & Johnson, E. N. (2016). Electric multirotor UAV propulsion system sizing for performance prediction and design optimization. In *57th AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference* (p. 0581).
- Betti Sorbelli, F. (2024). UAV-based delivery systems: A systematic review, current trends, and research challenges. *Journal on Autonomous Transportation Systems*, 1(3), 1-40.

- Brito, R. C., Lorencena, M. C., Loureiro, J. F., Favarim, F., & Todt, E. (2019, July). A comparative approach on the use of unmanned aerial vehicles kind of fixed-wing and rotative wing applied to the precision agriculture scenario. In 2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC) (Vol. 2, pp. 522-526). IEEE.
- Chapala, S. R., Pirati, G. S., & Nelakuditi, U. R. (2016, August). Determination of coordinate transformations in UAVS. In 2016 Second International Conference on Cognitive Computing and Information Processing (CCIP) (pp. 1-5). IEEE.
- Che Man, M. H., Haoliang, H., & Low, K. H. (2022). Crash Area Estimation for Ground Risk of Small Unmanned Aerial Vehicles Due to Propulsion System Failures. In AIAA SCITECH 2022 Forum (p. 1506).
- Chen, H., Lan, Y., Fritz, B. K., Hoffmann, W. C., & Liu, S. (2021). Review of agricultural spraying technologies for plant protection using unmanned aerial vehicle (UAV). *International Journal of Agricultural and Biological Engineering*, 14(1), 38-49.
- Chen, H., Lyu, Y., Shi, J., & Zhang, W. (2024). UAV anomaly detection method based on convolutional autoencoder and support vector data description with 0/1 soft-margin loss. *Drones*, 8(10), 534. <https://doi.org/10.3390/drones8100534>
- Chen, X., Jiang, K., Zhu, Y., Wang, X., & Yun, T. (2021). Individual tree crown segmentation directly from UAV-borne LiDAR data using the PointNet of deep learning. *Forests*, 12(2), 131.
- Cheng, N., Wu, S., Wang, X., Yin, Z., Li, C., Chen, W., & Chen, F. (2023). AI for UAV-assisted IoT applications: A comprehensive review. *IEEE Internet of Things Journal*, 10(16), 14438-14461.
- Chittoor, P. K., Chokkalingam, B., & Mihet-Popa, L. (2021). A review on UAV wireless charging: Fundamentals, applications, charging techniques and standards. *IEEE access*, 9, 69235-69266.
- Coşkun, M. Z. (2012). Düşük Maliyetli İHA (İnsansız Hava Aracı) ile Mobil Harita Üretiminin Bugünü ve Geleceği. *Harita Teknolojileri Elektronik Dergisi*, 4(2), 11-18.
- Danilov, A. S., Smirnov, U. D., & Pashkevich, M. A. (2015). The system of the ecological monitoring of environment which is based on the usage of UAV. *Russian journal of ecology*, 46(1), 14-19.
- Delavarpour, N., Koparan, C., Nowatzki, J., Bajwa, S., & Sun, X. (2021). A technical study on UAV characteristics for precision agriculture applications and associated practical challenges. *Remote Sensing*, 13(6), 1204.
- Dewi, P. T., Hadi, G. S., Kusnaedi, M. R., Budiarto, A., & Budiyo, A. (2015). Design of separate lift and thrust hybrid unmanned aerial vehicle. *Journal of Instrumentation, Automation, and Systems*, 2(2), 45-51.

- Eisenbeiss, H. (2004). A mini unmanned aerial vehicle (UAV): system overview and image acquisition. *International Archives of Photogrammetry. Remote Sensing and Spatial Information Sciences*, 36(5/W1), 1-7.
- El Adawy, M., Abdelhalim, E. H., Mahmoud, M., Mohamed, I. H., Othman, M. M., ElGamal, G. S., & ElShabasy, Y. H. (2023). Design and fabrication of a fixed-wing Unmanned Aerial Vehicle (UAV). *Ain Shams Engineering Journal*, 14(9), 102094.
- El-Atab, N., Mishra, R. B., Alshanbari, R., & Hussain, M. M. (2021). Solar powered small unmanned aerial vehicles: A review. *Energy Technology*, 9(12), 2100587.
- Eleftheroglou, N., Mansouri, S. S., Loutas, T., Karvelis, P., Georgoulas, G., Nikolakopoulos, G., & Zarouchas, D. (2019). Intelligent data-driven prognostic methodologies for the real-time remaining useful life until the end-of-discharge estimation of the Lithium-Polymer batteries of unmanned aerial vehicles with uncertainty quantification. *Applied Energy*, 254, 113677.
- Erenoglu, R. C., Erenoglu, O., & Arslan, N. (2018). Accuracy assessment of low cost UAV based city modelling for urban planning. *Tehnički vjesnik*, 25(6), 1708-1714.
- Fan, B., Li, Y., Zhang, R., & Fu, Q. (2020). Review on the technological development and application of UAV systems. *Chinese Journal of Electronics*, 29(2), 199-207.
- Fang, X., Tan, X., Zhang, C., Gao, X., & He, Z. (2025). Cross-system anomaly detection in deep-sea submersibles via coupled feature learning. *Symmetry*, 17(11), 1838. <https://doi.org/10.3390/sym17111838>
- Flores, D. A., Saito, C., Paredes, J. A., & Trujillano, F. (2017, February). Multispectral imaging of crops in the Peruvian Highlands through a fixed-wing UAV system. In *2017 IEEE International Conference on Mechatronics (ICM)* (pp. 399-403). IEEE.
- Fourlas, G. K., & Karras, G. C. (2021, June). A survey on fault diagnosis methods for UAVs. In *2021 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 394-403). IEEE.
- Franco, B. J. D. O. M., & Góes, L. C. S. (2007, November). Failure analysis methods in unmanned aerial vehicle (UAV) applications. In *Proceedings of COBEM 2007 19th International Congress of Mechanical Engineering* (p. 11).
- Frasca, D., Venturi, G., Ustenko, M., & Zanasi, A. (2023, November). Technologies for IMINT and SIGINT. In *2023 IEEE International Workshop on Technologies for Defense and Security (TechDefense)* (pp. 165-169). IEEE.
- Gadalla, M., & Zafar, S. (2016). Analysis of a hydrogen fuel cell-PV power system for small UAV. *International Journal of Hydrogen Energy*, 41(15), 6422-6432.

- Gaire, U. S. (2023). Application of artificial intelligence in the military: An overview. *Unity Journal*, 4(01), 161-174.
- Garg, P. K. (2022). Characterisation of fixed-wing versus multirotors UAVs/Drones. *Journal of Geomatics*, 16(2), 152-159.
- Ghasri, M., & Maghrebi, M. (2021). Factors affecting unmanned aerial vehicles' safety: A post-occurrence exploratory data analysis of drones' accidents and incidents in Australia. *Safety science*, 139, 105273.
- Giribet, J. I., Sanchez-Pena, R. S., & Ghersin, A. S. (2016). Analysis and design of a tilted rotor hexacopter for fault tolerance. *IEEE Transactions on aerospace and electronic systems*, 52(4), 1555-1567.
- Gomez, C., & Purdie, H. (2016). UAV-based photogrammetry and geocomputing for hazards and disaster risk monitoring—a review. *Geoenvironmental Disasters*, 3, 1-11.
- Gu, H., Lyu, X., Li, Z., Shen, S., & Zhang, F. (2017, June). Development and experimental verification of a hybrid vertical take-off and landing (VTOL) unmanned aerial vehicle (UAV). In *2017 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 160-169). IEEE.
- Guitton, M. J. (2021). Fighting the locusts: Implementing military countermeasures against drones and drone swarms. *Scandinavian Journal of Military Studies*, 4(1).
- Gupte, S., Mohandas, P. I. T., & Conrad, J. M. (2012). A survey of quadrotor unmanned aerial vehicles. *2012 Proceedings of IEEE Southeastcon*, 1-6.
- Hossain, N. U. I., Sakib, N., & Govindan, K. (2022). Assessing the performance of unmanned aerial vehicle for logistics and transportation leveraging the Bayesian network approach. *Expert Systems with Applications*, 209, 118301.
- Hosseini, N., Jamal, H., Haque, J., Magesacher, T., & Matolak, D. W. (2019, March). UAV command and control, navigation and surveillance: A review of potential 5G and satellite systems. In *2019 IEEE Aerospace Conference* (pp. 1-10). IEEE.
- Hyypä, E., Hyypä, J., Hakala, T., Kukko, A., Wulder, M. A., White, J. C., ... & Kaartinen, H. (2020). Under-canopy UAV laser scanning for accurate forest field measurements. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 41-60.
- Illeez, M. (2014). Capabilities of Unmanned Aircraft Systems in Hybrid Wars. *International Journal of Unmanned Systems Engineering*, 2(4), 46.
- Jasra, S. K., Valentino, G., Muscat, A., & Camilleri, R. (2025). A comparative study of unsupervised deep learning methods for anomaly detection in flight data. *Aerospace*, 12(7), 645. <https://doi.org/10.3390/aerospace12070645>

- Javaid, S., Saeed, N., Qadir, Z., Fahim, H., He, B., Song, H., & Bilal, M. (2023). Communication and control in collaborative UAVs: Recent advances and future trends. *IEEE Transactions on Intelligent Transportation Systems*, 24(6), 5719-5739.
- Jeon, S., Kang, J., Kim, J., & Cha, H. (2023). Detecting structural anomalies of quadcopter UAVs based on LSTM autoencoder. *Pervasive and Mobile Computing*, 88, 101736.
- Jia, M., Raja, A., & Yuan, J. (2023, February). A hybrid delay-aware approach towards UAV flight data anomaly detection. In *2023 international conference on computing, networking and communications (ICNC)* (pp. 176-180). IEEE.
- Jung, Y., Park, E.-G., Jeong, S.-H., & Kim, J.-H. (2024). AI-based anomaly detection techniques for structural fault diagnosis using low-sampling-rate vibration data. *Aerospace*, 11(7), 509. <https://doi.org/10.3390/aerospace11070509>
- Kasapoğlu, D. C., & Kırdemir, B. (2018). Yükselen insansız sistemler gücü: askeri atılımının eşiğindeki türkiye. *Dış Politika ve Güvenlik Arşivleri*, 11.
- Keane, J. F., & Carr, S. S. (2013). A brief history of early unmanned aircraft. *Johns Hopkins APL Technical Digest*, 32(3), 558-571.
- Keipour, A., Mousaei, M., & Scherer, S. (2021). Alfa: A dataset for uav fault and anomaly detection. *The International Journal of Robotics Research*, 40(2-3), 515-520.
- Khan, W., & Nahon, M. (2015, June). Real-time modeling of agile fixed-wing UAV aerodynamics. In *2015 international conference on unmanned aircraft systems (ICUAS)* (pp. 1188-1195). IEEE.
- Kinaneva, D., Hristov, G., Raychev, J., & Zahariev, P. (2019, May). Early forest fire detection using drones and artificial intelligence. In *2019 42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)* (pp. 1060-1065). IEEE.
- Kizito, R., Scruggs, P., Li, X., Devinney, M., Jansen, J., & Kress, R. (2021). Long short-term memory networks for facility infrastructure failure and remaining useful life prediction. *Ieee Access*, 9, 67585-67594. <https://doi.org/10.1109/access.2021.3077192>.
- Laloix, T., Iung, B., Voisin, A., & Romagne, E. (2019). Parameter identification of health indicator aggregation for decision-making in predictive maintenance: Application to machine tool. *CIRP Annals*, 68(1), 483-486.
- Lee, C., Kim, S., & Chu, B. (2021). A survey: Flight mechanism and mechanical structure of the UAV. *International Journal of Precision Engineering and Manufacturing*, 22(4), 719-743.
- Li, J., Liu, H., Lai, K. K., & Ram, B. (2022). Vehicle and UAV collaborative delivery path optimization model. *Mathematics*, 10(20), 3744.

- Li, N., Su, Z., Ling, H., Karatas, M., & Zheng, Y. (2023). Optimization of air defense system deployment against reconnaissance drone swarms. *Complex System Modeling and Simulation*, 3(2), 102-117.
- Li, Y., Fu, C., Huang, Z., Zhang, Y., & Pan, J. (2020, May). Keyfilter-aware real-time uav object tracking. In *2020 IEEE International Conference on Robotics and Automation (ICRA)* (pp. 193-199). IEEE.
- Liao, Z., Zhang, A., Li, S., Zhang, Y., & Zhou, P. (2023, October). A Data-Driven CEEMDAN-DRSCN-Based RUL Prediction Method for UAV Batteries. In *2023 Global Reliability and Prognostics and Health Management Conference (PHM-Hangzhou)* (pp. 1-5). IEEE.
- Liu, X., Chen, M., Liu, Y., Chen, Y., Cui, S., & Hanzo, L. (2020). Artificial intelligence aided next-generation networks relying on UAVs. *IEEE Wireless Communications*, 28(1), 120-127.
- Liu, Y., Wang, Y., Li, H., & Ai, J. (2024). Runway-Free Recovery Methods for Fixed-Wing UAVs: A Comprehensive Review. *Drones*, 8(9), 463.
- Lu, B., Dao, P. D., Liu, J., He, Y., & Shang, J. (2020). Recent advances of hyperspectral imaging technology and applications in agriculture. *Remote Sensing*, 12(16), 2659.
- Lu, C., Wang, Z. Y., Qin, W. L., & Ma, J. (2017). Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification. *Signal Processing*, 130, 377-388.
- Lu, H., Li, Y., Mu, S., Wang, D., Kim, H., & Serikawa, S. (2017). Motor anomaly detection for unmanned aerial vehicles using reinforcement learning. *IEEE internet of things journal*, 5(4), 2315-2322.
- Ma, H., Tsang, Y. P., & Lee, C. K. M. (2025). Optimizing multi-objective instant logistics with trucks and drones for the quick commerce order fulfilment. *Journal of Industrial and Production Engineering*, 1-17.
- Mansouri, S. S., Karvelis, P., Georgoulas, G., & Nikolakopoulos, G. (2017). Remaining useful battery life prediction for UAVs based on machine learning. *IFAC-PapersOnLine*, 50(1), 4727-4732.
- Messaoudi, K., Oubbati, O. S., Rachedi, A., Lakas, A., Bendouma, T., & Chaib, N. (2023). A survey of UAV-based data collection: Challenges, solutions and future perspectives. *Journal of network and computer applications*, 216, 103670.
- Mohsan, S. A. H., Othman, N. Q. H., Li, Y., Alsharif, M. H., & Khan, M. A. (2023). Unmanned aerial vehicles (UAVs): Practical aspects, applications, open challenges, security issues, and future trends. *Intelligent service robotics*, 16(1), 109-137.

- Morton, S., D'Sa, R., & Papanikolopoulos, N. (2015, September). Solar powered UAV: Design and experiments. In 2015 IEEE/RSJ international conference on intelligent robots and systems (IROS) (pp. 2460-2466). IEEE.
- Motlagh, N. H., Bagaa, M., & Taleb, T. (2017). UAV-based IoT platform: A crowd surveillance use case. *IEEE Communications Magazine*, 55(2), 128-134.
- Muda, N. R. S., & Sudarsono, R. A. (2024). DESIGN OF ENEMY DESTROYER KAMIKAZE DRONE BY DIPOLE_31 TECHNOLOGY. *Jurnal Pengabdian Mandiri*, 3(11), 1055-1066.
- Mustafa, A., Jamil, A., & Hameed, A. A. (2024, April). Machine Learning Based Techniques for Failure Detection and Prediction in Unmanned Aerial Vehicle. In 2024 IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI) (pp. 1-5). IEEE.
- Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4(51-62), 56.
- Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. *Remote Sensing*, 13(19), 3841.
- Nguyen, T. X. B., Rosser, K., & Chahl, J. (2021). A review of modern thermal imaging sensor technology and applications for autonomous aerial navigation. *Journal of Imaging*, 7(10), 217.
- Niemiec, R., Gandhi, F., & Singh, R. (2018). Control and performance of a reconfigurable multicopter. *Journal of Aircraft*, 55(5), 1855-1866.
- Omer, O. A., Hussein, S., & Mohamed, E. A. A. (2023). Solar Cell Anomaly Detection Based on Wavelet Scattering Transform and Artificial Intelligence. *Aswan University Journal of Sciences and Technology*, 3(1), 1-10.
- Ozkat, E. C. (2024). Vibration data-driven anomaly detection in UAVs: A deep learning approach. *Engineering Science and Technology, an International Journal*, 54, 101702.
- Ozkat, E. C., Bektas, O., Nielsen, M. J., & la Cour-Harbo, A. (2023). A data-driven predictive maintenance model to estimate RUL in a multi-rotor UAS. *International Journal of Micro Air Vehicles*, 15, 17568293221150171.
- Palomba, G., Crupi, V., & Epasto, G. (2022). Additively manufactured lightweight monitoring drones: Design and experimental investigation. *Polymer*, 241, 124557.
- Pan, D., Nie, L., Kang, W., & Song, Z. (2020, October). UAV anomaly detection using active learning and improved S3VM model. In 2020 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence (ICSMD) (pp. 253-258). IEEE.

- Pan, Z. F., An, L., & Wen, C. Y. (2019). Recent advances in fuel cells based propulsion systems for unmanned aerial vehicles. *Applied Energy*, 240, 473-485.
- Park, J. H., Choi, S. C., Ahn, I. Y., & Kim, J. (2019, January). Multiple UAVs-based surveillance and reconnaissance system utilizing IoT platform. In 2019 International conference on electronics, information, and communication (ICEIC) (pp. 1-3). IEEE.
- Patel, S., Sarabakha, A., Kircali, D., & Kayacan, E. (2020). An intelligent hybrid artificial neural network-based approach for control of aerial robots. *Journal of Intelligent & Robotic Systems*, 97(2), 387-398.
- Petritoli, E., Leccese, F., & Ciani, L. (2018, June). Reliability degradation, preventive and corrective maintenance of UAV systems. In 2018 5th IEEE International Workshop on Metrology for AeroSpace (MetroAeroSpace) (pp. 430-434). IEEE.
- Prior, S. D. (2010). Reviewing and investigating the use of co-axial rotor systems in small UAVs. *International Journal of Micro Air Vehicles*, 2(1), 1-16.
- Prisacariu, V. (2017). The history and the evolution of UAVs from the beginning till the 70s. *Journal of Defense Resources Management (JoDRM)*, 8(1), 181-189.
- Rao, B., Gopi, A. G., & Maione, R. (2016). The societal impact of commercial drones. *Technology in society*, 45, 83-90.
- Recoskie, S., Fahim, A., Gueaieb, W., & Lanteigne, E. (2013). Hybrid power plant design for a long-range dirigible UAV. *IEEE/ASME Transactions on Mechatronics*, 19(2), 606-614.
- Reddy, P. S., Deepa, K., & Sangeetha, S. T. (2024, April). Case Study on Predictive Modeling of UAV Battery Remaining Useful Life Using Machine Learning Regression Techniques. In 2024 International Conference on E-mobility, Power Control and Smart Systems (ICEMPS) (pp. 1-5). IEEE.
- Rehan, M., Akram, F., Shahzad, A., Shams, T. A., & Ali, Q. (2022). Vertical take-off and landing hybrid unmanned aerial vehicles: An overview. *The Aeronautical Journal*, 126(1306), 2017-2057.
- Sadi, M. (2020). UAV-based Forest Fire Detection and Localization Using Visual and Thermal Cameras (Doctoral dissertation, Concordia University).
- Saeed, A. S., Younes, A. B., Islam, S., Dias, J., Seneviratne, L., & Cai, G. (2015, June). A review on the platform design, dynamic modeling and control of hybrid UAVs. In 2015 International Conference on Unmanned Aircraft Systems (ICUAS) (pp. 806-815). IEEE.
- Saied, M., Lussier, B., Fantoni, I., Shraim, H., & Francis, C. (2017). Fault Diagnosis and Fault-Tolerant Control of an Octorotor UAV using motors speeds measurements. *IFAC-PapersOnLine*, 50(1), 5263-5268.

- Sangeetha, R. G., Srivastava, Y., Hemanth, C., Naicker, H. S., Kumar, A. P., & Nair, S. V. (2024). Unmanned Aerial Surveillance and Tracking System in Forest Areas for Poachers and Wildlife. *IEEE Access*.
- Scalea, J. R., Pucciarella, T., Talaie, T., Restaino, S., Drachenberg, C. B., Alexander, C., ... & Scassero, M. (2021). Successful implementation of unmanned aircraft use for delivery of a human organ for transplantation. *Annals of surgery*, 274(3), e282-e288.
- Segui-Gasco, P., Al-Rihani, Y., Shin, H. S., & Savvaris, A. (2014). A novel actuation concept for a multi rotor UAV. *Journal of Intelligent & Robotic Systems*, 74, 173-191.
- Shakhatreh, H., Sawalmeh, A. H., Al-Fuqaha, A., Dou, Z., Almaita, E., Khalil, I., ... & Guizani, M. (2019). Unmanned aerial vehicles (UAVs): A survey on civil applications and key research challenges. *IEEE Access*, 7, 48572-48634.
- Shi, Z., Zhu, J., Dai, X., Chen, K., Zhang, T., Wang, H., ... & Zhang, P. (2019). Aerodynamic characteristics and flight testing of a UAV without control surfaces based on circulation control. *Journal of Aerospace Engineering*, 32(1), 04018134.
- Skorput, P., Mandzuka, S., & Vojvodic, H. (2016, September). The use of Unmanned Aerial Vehicles for forest fire monitoring. In 2016 International Symposium ELMAR (pp. 93-96). *IEEE*.
- Song, C., Zang, Y., Zhou, Z., Luo, X., Zhao, L., Ming, R., ... & Zang, Y. (2020). Test and comprehensive evaluation for the performance of UAV-based fertilizer spreaders. *IEEE Access*, 8, 202153-202163.
- Sudhakar, S., Vijayakumar, V., Kumar, C. S., Priya, V., Ravi, L., & Subramaniaswamy, V. (2020). Unmanned Aerial Vehicle (UAV) based Forest Fire Detection and monitoring for reducing false alarms in forest-fires. *Computer Communications*, 149, 1-16.
- Suresh, M., & Ghose, D. (2012). UAV grouping and coordination tactics for ground attack missions. *IEEE Transactions on Aerospace and Electronic Systems*, 48(1), 673-692.
- Tariq, M., Saadat, A., Ahmad, R., Abaid, Z., & Rodrigues, J. J. (2023). Enhanced border surveillance through a hybrid swarm optimization algorithm. *IEEE Sensors Journal*, 23(22), 28172-28181.
- Tatham, P., Neal, C., & Wu, Y. (2017). Hybrid cargo airships: a humanitarian logistic game changer?. *Journal of Humanitarian Logistics and Supply Chain Management*, 7(2), 102-125.
- Titouna, C., Naït-Abdesselam, F., & MOUNGLA, H. (2020, June). An online anomaly detection approach for unmanned aerial vehicles. In 2020 International Wireless Communications and Mobile Computing (IWCMC) (pp. 469-474). *IEEE*.

- Türkseven, S., Kızmaz, M. Z., Tekin, A. B., Urkan, E., & Serim, A. T. (2016). Tarımda dijital dönüşüm; insansız hava araçları kullanımı. *Tarım Makinaları Bilimi Dergisi*, 12(4), 267-271.
- Udeanu, G., Dobrescu, A., & Oltean, M. (2016). Unmanned aerial vehicle in military operations. *Sci. Res. Educ. Air Force*, 18(1), 199-206.
- Usama, M., Qadir, J., Raza, A., Arif, H., Yau, K. L. A., Elkhatib, Y., ... & Al-Fuqaha, A. (2019). Unsupervised machine learning for networking: Techniques, applications and research challenges. *IEEE Access*, 7, 65579-65615.
- Velusamy, P., Rajendran, S., Mahendran, R. K., Naseer, S., Shafiq, M., & Choi, J. G. (2021). Unmanned Aerial Vehicles (UAV) in precision agriculture: Applications and challenges. *Energies*, 15(1), 217.
- Venkatesh, S. N., & Sugumaran, V. (2022). A combined approach of convolutional neural networks and machine learning for visual fault classification in photovoltaic modules. *Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability*, 236(1), 148-159.
- Verbeke, J., & Schutter, J. D. (2018). Experimental maneuverability and agility quantification for rotary unmanned aerial vehicle. *International Journal of Micro Air Vehicles*, 10(1), 3-11.
- Villa, T. F., Salimi, F., Morton, K., Morawska, L., & Gonzalez, F. (2016). Development and validation of a UAV based system for air pollution measurements. *Sensors*, 16(12), 2202.
- Walia, S. S., Somarathna, K. U. S., Hendricks, R., Jackson, A., & Nagarur, N. (2018). Optimizing the emergency delivery of medical supplies with unmanned aircraft vehicles. In *IIE Annual Conference. Proceedings* (pp. 1588-1593). Institute of Industrial and Systems Engineers (IISE).
- Wang, H., Cheng, H., & Hao, H. (2020, September). The use of unmanned aerial vehicle in military operations. In *International Conference on Man-Machine-Environment System Engineering* (pp. 939-945). Singapore: Springer Singapore.
- Wang, J., Jiang, C., Wei, Z., Pan, C., Zhang, H., & Ren, Y. (2018). Joint UAV hovering altitude and power control for space-air-ground IoT networks. *IEEE Internet of Things Journal*, 6(2), 1741-1753.
- Wang, M., Fu, W., He, X., Hao, S., & Wu, X. (2020). A survey on large-scale machine learning. *IEEE Transactions on Knowledge and Data Engineering*, 34(6), 2574-2594.
- Wang, S., Jiang, F., Zhang, B., Ma, R., & Hao, Q. (2019). Development of UAV-based target tracking and recognition systems. *IEEE Transactions on Intelligent Transportation Systems*, 21(8), 3409-3422.

- Wellig, P., Speirs, P., Schuepbach, C., Oechslin, R., Renker, M., Boeniger, U., & Pratisto, H. (2018, June). Radar systems and challenges for C-UAV. In 2018 19th International Radar Symposium (IRS) (pp. 1-8). IEEE.
- Xiaowei, W. (2023, February). An Optimized CNN-SVM Algorithm for UAV Anomaly Detection. In 2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA) (pp. 1488-1494). IEEE.
- Yılmaz, A., & Ulvi, H. (2022). Kentsel hava sahasında insansız hava aracı sistemleri trafik yönetimi için verilmesi gereken hizmetler ve kullanılabilecek bazı teknolojiler. *Türkiye İnsansız Hava Araçları Dergisi*, 4(1), 8-18.
- Zahra, N., Buldan, R. S., Nazaruddin, Y. Y., & Widyotriatmo, A. (2021, May). Predictive maintenance with neural network approach for UAV propulsion systems monitoring. In 2021 American Control Conference (ACC) (pp. 2631-2636). IEEE.
- Zaloga, S. J. (2011). V-1 Flying Bomb 1942–52: Hitler’s infamous “doodlebug” (Vol. 106). Bloomsbury Publishing.
- Zhang, S., Robinson, E., & Basu, M. (2023). Wind turbine predictive fault diagnostics based on a novel long short-term memory model. *Algorithms*, 16(12), 546. <https://doi.org/10.3390/a16120546>.
- Zhao, T., & Li, W. (2022). Design configuration and technical application of rotary-wing unmanned aerial vehicles. *Mechatronics and Intelligent Transportation Systems*, 1(1), 69-85.
- Zhong, J., Zhang, Y., Wang, J., Luo, C., & Miao, Q. (2021). Unmanned aerial vehicle flight data anomaly detection and recovery prediction based on spatio-temporal correlation. *IEEE Transactions on Reliability*, 71(1), 457-468.
- Zhou, M., Zhou, Z., Liu, L., Huang, J., & Lyu, Z. (2020). Review of vertical take-off and landing fixed-wing UAV and its application prospect in precision agriculture. *International Journal of Precision Agricultural Aviation*, 3(4).
- Zhu, H., Nie, H., Zhang, L., Wei, X., & Zhang, M. (2020). Design and assessment of octocopter drones with improved aerodynamic efficiency and performance. *Aerospace Science and Technology*, 106, 106206.