



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY ZEKA İLE DÖRT MOTORLU İHA
PERVANE HASAR TESPİTİ VE DÜŞME
RİSKİ TAHMİNİ

Mehmet Reha KOÇAK

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Haziran-2026
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Mehmet Reha Koak tarafından hazırlanan “Yapay Zeka İle Dört Motorlu İha Pervane Hasar Tespiti Ve Düşme Riski Tahmini” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Hulusi KARACA

Danışman

Doç. Dr. Muhammed Fahri ÜNLERŞEN

Üye

Doç. Dr. Sabri ALTUNKAYA

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

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

DECLARATION PAGE

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

İmza

Mehmet Reha KOÇAK

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY ZEKA İLE DÖRT MOTORLU İHA PERVANE HASAR TESPİTİ VE DÜŞME RİSKİ TAHMİNİ

Mehmet Reha KOÇAK

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Doç. Dr. Muhammed Fahri ÜNLERŞEN

2026, 92 Sayfa

Jüri

Doç. Dr. Muhammed Fahri ÜNLERŞEN

Doç. Dr. Hulusi KARACA

Doç. Dr. Sabri ALTUNKAYA

İnsansız Hava Araçları (İHA), son yıllarda sivil ve askeri alanlarda hızla yaygınlaşan kritik teknolojiler arasında yer almaktadır. Bu sistemlerin operasyonel güvenliği, bileşenlerinin kusursuz çalışmasına doğrudan bağlıdır. Quadrotor platformlarda pervaneler, itki kuvveti üreten ve uçuş stabilitesini sağlayan en kritik bileşenler olup çevresel faktörlere karşı en savunmasız elemanlardır. Pervane hasarları, sistemde asimetrik itki dağılımı, kontrol gücü ve hatta tam kontrol kaybına yol açabilmektedir. Geleneksel görsel denetim yöntemleri, başlangıç aşamasındaki hasarları tespit etmekte yetersiz kalmakta ve yoğun iş gücü gerektirmektedir.

Bu tez çalışmasında, quadrotor platformlarda pervane hasarının gerçek zamanlı tespiti ve sınıflandırılması için IMU (Eylemsizlik Ölçüm Birimi) tabanlı bir makine öğrenmesi yaklaşımı geliştirilmiştir. Çalışmada 550 mm gövde boyutuna sahip, Cube Orange uçuş kontrolcüsü ile donatılmış bir quadrotor platform kullanılmıştır. Deneyler, kontrollü laboratuvar ortamı yerine gerçek açık alan koşullarında ve GPS destekli otonom uçuş modunda gerçekleştirilmiştir. Pervane hasarı, Motor 1 (ön sağ) pervanesinin tek kanadına kademeli kesimler uygulanarak dört farklı seviyede (hasarsız, hafif, orta ve ağır) oluşturulmuştur. Hasar seviyeleri pervane yarıçapının sırasıyla %0, %3, %6 ve %8'ine karşılık gelmektedir.

Veri toplama sürecinde iki farklı uçuş senaryosu (dairesel ve sekiz rotası) kullanılarak toplam 8.261 örnek içeren bir veri seti oluşturulmuştur. Ham sensör verilerinden 255 adet özellik çıkarılmış olup bu özellikler istatistiksel metrikler, frekans domain özellikleri, motor dengesizlik göstergeleri ve tutum hata metrikleri kategorilerinde gruplandırılmıştır. Özellik çıkarımında 40 örneklik kayan pencere yöntemi uygulanmıştır.

Hasar tespiti ve sınıflandırılması için altı farklı makine öğrenmesi algoritması (K-En Yakın Komşu, Karar Ağacı, Rastgele Orman, Doğrusal SVM, RBF Çekirdekli SVM ve Naive Bayes) sistematik olarak karşılaştırılmıştır. Tüm algoritmalar için Grid Search yöntemiyle hiperparametre optimizasyonu gerçekleştirilmiş ve 5-katlı çapraz doğrulama ile model güvenilirliği değerlendirilmiştir.

DeneySEL sonuçlar, Karar Ağacı algoritmasının %94,81 test doğruluğu ile en yüksek performansı gösterdiğini ortaya koymuştur. Rastgele Orman %93,51, Doğrusal SVM %87,01, RBF Çekirdekli SVM %85,71 ve KNN %84,42 doğruluk değerleri elde etmiştir. Sınıf bazlı analizde hasarsız ve kritik hasar sınıfları %100'e yakın doğrulukla ayırt edilebilmiştir. Çapraz doğrulama sonuçları, RBF Çekirdekli SVM'in %90,5 ortalama ile en yüksek CV skoruna sahip olduğunu göstermiştir. Özellik önemi analizi, X eksenini titreşim verilerinin pervane hasarı tespiti ve sınıflandırılmasında en güçlü prediktörler olduğunu ortaya koymuştur.

Bu çalışma, quadrotor platformlarda pervane hasarının titreşim verileri ve makine öğrenmesi algoritmaları kullanılarak yüksek doğrulukla tespit edilip sınıflandırılabilirliğini göstermiştir. Geliştirilen yaklaşım, düşük maliyetli, gerçek zamanlı ve pratik uygulanabilir bir çözüm sunarak İHA operasyonel güvenliğinin artırılmasına katkıda bulunmaktadır.

Anahtar Kelimeler: Hasar Sınıflandırma, İnsansız Hava Aracı, Makine Öğrenmesi, Pervane Hasar Tespiti, Quadrotor, Titreşim Analizi



ABSTRACT

MS THESIS

PROPELLER DAMAGE DETECTION AND CRASH RISK PREDICTION FOR QUADROTOR UAVS USING ARTIFICIAL INTELLIGENCE

Mehmet Reha KOÇAK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES OF
NECMETTİN ERBAKAN UNIVERSITY THE DEGREE OF MASTER OF
SCIENCE
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Assoc. Prof. Dr. Muhammed Fahri ÜNLERŞEN

2026, 92 Pages

Jury

Assoc. Prof. Dr. Muhammed Fahri ÜNLERŞEN

Assoc. Prof. Dr. Hulusi KARACA

Assoc. Prof. Dr. Sabri ALTUNKAYA

Unmanned Aerial Vehicles (UAVs) have emerged as critical technologies that have rapidly proliferated in both civilian and military domains in recent years. The operational safety of these systems is directly dependent on the flawless functioning of their components. On quadrotor platforms, propellers are the most critical components that generate thrust force and ensure flight stability, while also being the most vulnerable elements to environmental factors. Propeller damage can lead to asymmetric thrust distribution, control difficulties, and even complete loss of control in the system. Conventional visual inspection methods are inadequate for detecting damage at early stages and require intensive labor.

In this thesis, an IMU (Inertial Measurement Unit)-based machine learning approach has been developed for real-time detection and classification of propeller damage on quadrotor platforms. The study utilized a quadrotor platform with a 550 mm frame size, equipped with a Cube Orange flight controller. Experiments were conducted under real outdoor conditions with GPS-assisted autonomous flight mode, rather than in a controlled laboratory environment. Propeller damage was created at four different levels (undamaged, mild, moderate, and severe) by applying incremental cuts to a single blade of Motor 1 (front right) propeller. The damage levels correspond to 0%, 3%, 6%, and 8% of the propeller radius, respectively.

During the data collection process, a dataset containing a total of 8,261 samples was created using two different flight scenarios (circular and figure-eight trajectories). A total of 255 features were extracted from raw sensor data, grouped into categories including statistical metrics, frequency domain features, motor imbalance indicators, and attitude error metrics. A sliding window method with 40 samples was applied for feature extraction.

Six different machine learning algorithms (K-Nearest Neighbors, Decision Tree, Random Forest, Linear SVM, RBF Kernel SVM, and Naive Bayes) were systematically compared for damage detection and classification. Hyperparameter optimization was performed using the Grid Search method for all algorithms, and model reliability was evaluated with 5-fold cross-validation.

Experimental results revealed that the Decision Tree algorithm achieved the highest performance with 94,81% test accuracy. Random Forest achieved 93,51%, Linear SVM 87,01%, RBF Kernel SVM 85,71%, and KNN 84,42% accuracy values. In class-based analysis, undamaged and critical damage classes could be distinguished with near 100% accuracy. Cross-validation results showed that RBF Kernel SVM had the highest CV score with a 90,5% average. Feature importance analysis revealed that X-axis vibration data are the strongest predictors for propeller damage detection and classification.

This study has demonstrated that propeller damage on quadrotor platforms can be detected and classified with high accuracy using vibration data and machine learning algorithms. The developed approach contributes to enhancing UAV operational safety by providing a low-cost, real-time, and practically applicable solution.

Keywords: Damage Classification, Unmanned Aerial Vehicle, Machine Learning, Propeller Damage Detection, Quadrotor, Vibration Analysis



ÖNSÖZ

İnsansız Hava Araçları (İHA) teknolojisinin hızla geliştiği günümüzde, bu sistemlerin operasyonel güvenliğinin sağlanması ve sürdürülmesi teknolojik ilerlemenin en önemli hedeflerinden biri haline gelmiştir. Bu tez çalışması, quadrotor platformlarda pervane hasar tespiti ve sınıflandırılması için makine öğrenmesi tabanlı bir yaklaşım sunarak, alandaki mevcut yöntemlere alternatif ve pratik uygulanabilir bir çözüm geliştirme amacı taşımaktadır.

Çalışmanın hazırlanması sürecinde, özellikle son yıllarda yaşanan dijital dönüşümün İHA sektörüne olan etkilerinin arıza tespit sistemlerine yansımalarını anlamak büyük önem taşımıştır. Makine öğrenmesi algoritmalarının ve sensör teknolojilerinin hızla gelişmesi, geleneksel görsel denetim yöntemlerinin yeniden değerlendirilmesini ve veri odaklı yaklaşımların benimsenmesini gerekli kılmıştır. Bu çalışma, gerçek uçuş koşullarında toplanan veriler üzerinde yapılan deneysel analizlerle, İHA platformlarında proaktif bakım uygulamalarının geliştirilmesine katkı sağlamayı hedeflemektedir.

Bu çalışmanın ortaya çıkmasında değerli katkıları bulunan danışmanım Doç. Dr. Muhammed Fahri ÜNLERŞEN'e, tez sürecindeki rehberliği, yapıcı önerileri ve akademik desteği için en içten teşekkürlerimi sunarım. Ayrıca, Necmettin Erbakan Üniversitesi'nin sağladığı akademik ortam ve kaynaklardan yararlanma imkânı için müteşekkirim.

Çalışmanın İHA teknolojisi alanında faaliyet gösteren araştırmacılar ve sektör profesyonelleri için faydalı bir kaynak oluşturması temennisiyle.

Mehmet Reha KOÇAK
KONYA-2026

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	vi
ÖNSÖZ	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER LİSTESİ	xi
ÇİZELGELER/TABLolar LİSTESİ.....	xii
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ	1
2. MATERYAL VE YÖNTEM.....	13
2.1. İnsansız Hava Aracı Platformu	13
2.2. Deney Düzenegi ve Test Ortamı.....	15
2.2.1. Test ortamı	15
2.2.2. Uçuş parametreleri.....	16
2.2.3. Uçuş senaryoları	16
2.3. Pervane Hasar Protokolü	17
2.3.1. Hasar verme yöntemi	17
2.3.2. Hasar seviyeleri.....	18
2.4. Veri Toplama ve Kayıt	19
2.4.1. Veri formatı ve kaynağı	20
2.4.2. Veri seti özellikleri.....	20
2.5. Sensör Parametreleri	22
2.5.1. Kaydedilen sensör verileri	22
2.6. Veri Kalitesi Değerlendirmesi	24
2.6.1. Eksik veri analizi	24
2.6.2. Aykırı değer analizi	24
2.7. Veri Ön İşleme.....	25
2.7.1. Aykırı değer tespiti ve temizleme	26
2.7.2. Pencere tabanlı özellik çıkarımı.....	26
2.8. Özellik Mühendisliği	27
2.8.1. İstatistiksel özellikler	27
2.8.2. Motor dengesizlik özellikleri	27
2.8.3. Frekans domain özellikleri.....	27
2.8.4. Attitude hata özellikleri	28
2.9. Makine Öğrenmesi Modelleri.....	29
2.9.1. K-en yakın komşu (KNN) algoritması.....	30
2.9.2. Karar ağacı (Decision Tree) algoritması.....	30
2.9.3. Rastgele orman (Random Forest) algoritması	30
2.9.4. Destek vektör makinesi (SVM) algoritması	31
2.9.5. Naive Bayes algoritması	31
2.9.6. Hiperparametre optimizasyonu.....	31
2.9.7. Model doğrulama stratejisi	32

2.9.8. Performans metrikleri	33
3. BULGULAR.....	34
3.1. Model Performans Karşılaştırması	34
3.2. Çapraz Doğrulama Sonuçları.....	36
3.3. Sınıf Bazlı Performans Analizi	37
3.4. Karışıklık Matrisi Analizi	38
3.4.1. Karar Ağacı karışıklık matrisi.....	39
3.4.2. Rastgele Orman karışıklık matrisi	40
3.4.3. Doğrusal SVM karışıklık matrisi.....	41
3.4.4. RBF çekirdekli SVM karışıklık matrisi	42
3.4.5. K-En Yakın Komşu karışıklık matrisi	43
3.4.6. Naive Bayes karışıklık matrisi.....	44
3.5. ROC Eğrisi Analizi.....	44
3.5.1. Karar Ağacı ROC eğrisi.....	45
3.5.2. Rastgele Orman ROC eğrisi	46
3.5.3. Doğrusal SVM ROC eğrisi	47
3.5.4. RBF çekirdekli SVM ROC eğrisi	48
3.5.5. K-En Yakın Komşu ROC eğrisi	49
3.5.6. Naive Bayes ROC eğrisi	50
3.6. Precision-Recall Analizi	50
3.6.1. Karar Ağacı Precision-Recall eğrisi	51
3.6.2. Rastgele Orman Precision-Recall eğrisi	52
3.6.3. Doğrusal SVM Precision-Recall eğrisi.....	53
3.6.4. RBF çekirdekli SVM Precision-Recall eğrisi.....	54
3.6.5. K-En Yakın Komşu Precision-Recall eğrisi	55
3.6.6. Naive Bayes Precision-Recall eğrisi.....	56
3.7. Öğrenme Eğrileri ve Overfitting Analizi	56
3.7.1. Karar Ağacı öğrenme eğrisi	58
3.7.2. Rastgele Orman öğrenme eğrisi.....	59
3.7.3. Doğrusal SVM öğrenme eğrisi	60
3.7.4. RBF çekirdekli SVM öğrenme eğrisi	61
3.7.5. K-En Yakın Komşu öğrenme eğrisi.....	62
3.7.6. Naive Bayes öğrenme eğrisi	63
3.8. Özellik Önem Analizi	63
3.9. Fiziksel Sensör Verileri Analizi.....	65
3.9.1. Titreşim analizi	66
3.9.2. Tutum hataları analizi	67
3.9.3. Motor çıkışları analizi.....	68
3.10. Hesaplama Verimliliği Analizi	68
3.11. Bulgular Özeti.....	69
4. SONUÇ	70
5. KAYNAKÇA.....	74

ŞEKİLLER LİSTESİ

Şekil 2.1. Çalışmada kullanılan 550 mm quadcopter İHA platformu	13
Şekil 2.2. Konya'da bir yükseköğretim kurumu kampüs bahçesinde gerçekleştirilen uçuş testlerinden bir görünüm	15
Şekil 2.3. Pervaneye kontrollü hasar verme işlemi	17
Şekil 2.4. Pervane hasar seviyeleri bütüncül görünümü.....	18
Şekil 2.5. ArduPilot plot.ardupilot.org web arayüzü.....	20
Şekil 2.6. Veri seti sınıf dağılımı ve uçuş deseni dağılımı	22
Şekil 2.7. Sensör sinyalleri zaman serisi örnekleri.....	23
Şekil 2.8. Veri kalitesi değerlendirme grafiği.....	25
Şekil 2.9. Özellik dağılımları (hasar seviyelerine göre)	28
Şekil 2.10. Sensör korelasyon matrisi	28
Şekil 3.1. Model performans karşılaştırma grafiği	35
Şekil 3.2. F1-skoru bazında model sıralaması.....	35
Şekil 3.3. Çapraz doğrulama sonuçları	37
Şekil 3.4. Sınıf bazlı performans grafiği.....	38
Şekil 3.5. Tüm modellerin karışıklık matrisleri karşılaştırması	39
Şekil 3.6. Karar Ağacı karışıklık matrisi (Doğruluk: %94,81).....	40
Şekil 3.7. Rastgele Orman karışıklık matrisi (Doğruluk: %93,51)	41
Şekil 3.8. Doğrusal SVM karışıklık matrisi (Doğruluk: %87,01).....	42
Şekil 3.9. RBF çekirdekli SVM karışıklık matrisi (Doğruluk: %85,71)	43
Şekil 3.10. KNN karışıklık matrisi (Doğruluk: %84,42).....	44
Şekil 3.11. Naive Bayes karışıklık matrisi (Doğruluk: %54,55).....	44
Şekil 3.12. Tüm modellerin ROC eğrileri karşılaştırması	45
Şekil 3.13. Karar Ağacı ROC eğrisi	46
Şekil 3.14. Rastgele Orman ROC eğrisi.....	47
Şekil 3.15. Doğrusal SVM ROC eğrisi.....	48
Şekil 3.16. RBF çekirdekli SVM ROC eğrisi.....	49
Şekil 3.17. KNN ROC eğrisi	50
Şekil 3.18. Naive Bayes ROC eğrisi.....	50
Şekil 3.19. Tüm modellerin Precision-Recall eğrileri karşılaştırması.....	51
Şekil 3.20. Karar Ağacı Precision-Recall eğrisi	52
Şekil 3.21. Rastgele Orman Precision-Recall eğrisi.....	53
Şekil 3.22. Doğrusal SVM Precision-Recall eğrisi	54
Şekil 3.23. RBF çekirdekli SVM Precision-Recall eğrisi	55
Şekil 3.24. KNN Precision-Recall eğrisi	55
Şekil 3.25. Naive Bayes Precision-Recall eğrisi	56
Şekil 3.26. Tüm modellerin öğrenme eğrileri karşılaştırması	57
Şekil 3.27. Karar Ağacı öğrenme eğrisi	57
Şekil 3.28. Rastgele Orman öğrenme eğrisi	58
Şekil 3.29. Doğrusal SVM öğrenme eğrisi.....	59
Şekil 3.30. RBF çekirdekli SVM öğrenme eğrisi.....	60
Şekil 3.31. KNN öğrenme eğrisi	60
Şekil 3.32. Naive Bayes öğrenme eğrisi.....	61
Şekil 3.33. Rastgele Orman özellik önem grafiği.....	62
Şekil 3.34. Karar Ağacı özellik önem grafiği	63
Şekil 3.35. Hasar seviyelerine göre titreşim analizi	64
Şekil 3.36. Hasar seviyelerine göre tutum (attitude) hataları	65
Şekil 3.37. Hasar seviyelerine göre motor çıkışları.....	66

ÇİZELGELER/TABLolar LİSTESİ

Çizelge 2.1. İHA platformu teknik özellikleri	14
Çizelge 2.2. Pervane hasar seviyeleri	18
Çizelge 2.3. Veri seti genel özellikleri	21
Çizelge 2.4. Uçuş dosyaları detaylı özellikleri	21
Çizelge 2.5. Sensör grupları ve kanal sayıları	23
Çizelge 2.6. Kritik sensör parametreleri istatistikleri	24
Çizelge 2.7. Aykırı değer analizi sonuçları (IQR yöntemi).....	25
Çizelge 2.8. Veri işleme pipeline aşamaları	26
Çizelge 2.9. Hiperparametre arama uzayı	32
Çizelge 3.1. Model performans karşılaştırması (test seti, n=77)	35
Çizelge 3.2. Çapraz doğrulama sonuçları (5-Fold CV)	36
Çizelge 3.3. Karar Ağacı sınıf bazlı performans metrikleri	37
Çizelge 3.4. Karar Ağacı karışıklık matrisi	39
Çizelge 3.5. Eğitim-test doğruluk farkları ve overfitting analizi.....	57
Çizelge 3.6. En önemli 10 özellik (Rastgele Orman)	62
Çizelge 3.7. Hesaplama verimliliği metrikleri.....	67

SİMGELER VE KISALTMALAR

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

SİMGELER

g	Gram
Hz	Hertz
inç	İnç (1 inç = 25,4 mm)
KV	Hız sabiti
mAh	Miliamper saat
mm	Milimetre
ms	Milisaniye
s	Saniye
V	Volt
%	Yüzde

KISALTMALAR

BLDC	Brushless Direct Current (Fırçasız Doğru Akım)
CAGR	Compound Annual Growth Rate (Bileşik Yıllık Büyüme Oranı)
CNN	Convolutional Neural Network (Evrişimli Sinir Ağı)
CSV	Comma-Separated Values (Virgülle Ayrılmış Değerler)
CV	Cross-Validation (Çapraz Doğrulama)
DT	Decision Tree (Karar Ağacı)
DÖ	Derin Öğrenme
FAA	Federal Aviation Administration (ABD Federal Havacılık İdaresi)
FFT	Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FPGA	Field-Programmable Gate Array (Sahada Programlanabilir Kapı Dizisi)
FTC	Fault Tolerant Control (Hata Toleranslı Kontrol)
GPS	Global Positioning System (Küresel Konumlama Sistemi)
GRU	Gated Recurrent Unit (Geçitli Tekrarlayan Birim)
IMU	Inertial Measurement Unit (Eylemsizlik Ölçüm Birimi)
IQR	Interquartile Range (Çeyrekler Arası Aralık)
İHA	İnsansız Hava Aracı
KNN	K-Nearest Neighbors (K-En Yakın Komşu)
LiPo	Lithium Polymer (Lityum Polimer)
LSTM	Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MEMS	Micro-Electro-Mechanical Systems (Mikro-Elektromekanik Sistemler)
MÖ	Makine Öğrenmesi
PWM	Pulse Width Modulation (Darbe Genişlik Modülasyonu)
RBF	Radial Basis Function (Radyal Tabanlı Fonksiyon)
RF	Random Forest (Rastgele Orman)
ROC	Receiver Operating Characteristic
SVM	Support Vector Machine (Destek Vektör Makinesi)
VTOL	Vertical Take-Off and Landing (Dikey Kalkış ve İniş)
YSA	Yapay Sinir Ağı

1. GİRİŞ

İnsansız Hava Araçları (İHA), havacılık tarihinin en hızlı gelişen ve dönüştürücü teknolojilerinden biri olarak son on yılda hem sivil hem de askeri alanlarda devrim niteliğinde bir yükseliş yaşamış ve bu süreçte küresel ölçekte büyük bir ilgi odağı haline gelmiştir (Jia vd., 2025). Kökleri 20. yüzyılın başlarına dayanan insansız uçuş konsepti, başlangıçta askeri hedef uçakları ve keşif platformları olarak oldukça sınırlı bir kullanım alanına sahipken, günümüzde mikro-elektromekanik sistemler (MEMS), gelişmiş batarya teknolojileri, küçültülmüş hesaplama birimleri ve yapay zekâ algoritmalarındaki önemli atılımlar sayesinde çok geniş ve kapsamlı bir uygulama yelpazesine kavuşmuştur (Kalay ve Özkul, 2024). Özellikle 2010'lu yıllardan itibaren tüketici elektroniği sektöründeki minyatürleştirme trendinin İHA bileşenlerine belirgin şekilde yansması, bu sistemlerin hem üretim maliyetini önemli ölçüde düşürmüş hem de uçuş performansını kayda değer biçimde artırmıştır (Abdullah vd., 2025).

İHA'lar genel olarak sabit kanatlı, döner kanatlı ve hibrit platformlar olmak üzere üç ana kategoride sınıflandırılmaktadır ve her bir kategori kendine özgü avantaj ve dezavantajlar barındırmaktadır (Gatkal vd., 2025). Sabit kanatlı İHA'lar uzun menzil ve yüksek taşıma kapasitesi sunarken, döner kanatlı sistemler ise dikey kalkış-iniş (VTOL) yeteneği, havada asılı kalma (hover) kabiliyeti ve dar alanlarda manevra esnekliği gibi kritik ve vazgeçilmez avantajlar sağlamaktadır (João, 2025). Döner kanatlı platformlar arasında dört rotorlu yapılandırma olan quadrotorlar, mekanik basitlikleri, üretim kolaylıkları, yüksek manevra kabiliyetleri ve görece düşük maliyetleri nedeniyle hem akademik araştırma hem de ticari uygulamalarda en yaygın tercih edilen konfigürasyon konumuna ulaşmıştır (Qiu vd., 2024). Quadrotor sistemleri, dört bağımsız motorun diferansiyel hız kontrolü ile altı serbestlik derecesinde hareket edebilmekte ve bu sayede karmaşık uçuş görevlerini başarıyla ve güvenilir bir şekilde yerine getirebilmektedir (Zhong vd., 2025).

Günümüzde İHA teknolojisi, sahip olduğu esnek manevra kabiliyetleri ve düşük operasyonel maliyetleri sayesinde pek çok farklı sektörde vazgeçilmez ve kritik bir araç haline gelmiş durumdadır. Hassas tarım uygulamalarında İHA'lar, multispektral kameralar ve çeşitli sensörler yardımıyla bitki sağlığı analizi, sulama optimizasyonu, gübre ve pestisit uygulaması gibi önemli görevleri insan müdahalesine kıyasla çok daha verimli ve hızlı şekilde gerçekleştirmektedir (Chen vd., 2025). Enerji sektöründe ise

rüzgâr türbinleri, güneş panelleri, yüksek gerilim hatları ve boru hatlarının periyodik ve düzenli denetimi için İHA'lar yaygın biçimde kullanılmakta; bu sayede tehlikeli yüksekliklerde çalışan personel riski tamamen ortadan kaldırılırken denetim süreleri de önemli ölçüde kısalmaktadır (Gao vd., 2025). İnşaat ve madencilik sektörlerinde ise hacim hesaplaması, ilerleme takibi ve topografik haritalama için fotogrametri destekli İHA sistemleri yaygın ve etkin bir şekilde kullanılmaktadır (Poorghasem, 2025).

Arama-kurtarma operasyonlarında termal kameralarla donatılmış İHA'lar, geniş alanları oldukça kısa sürede tarayarak kayıp kişilerin tespitinde hayati ve kritik bir rol üstlenmekte ve bu sayede kurtarma operasyonlarının başarı oranını önemli ölçüde artırmaktadır (Masalimov vd., 2024). Lojistik ve teslimat sektöründe özellikle son mil teslimatı için İHA'lar denenmekte olup uzak ve erişilmesi güç bölgelere tıbbi malzeme, kan ürünleri ve acil yardım malzemesi ulaştırılmasında son derece başarılı sonuçlar elde edilmiştir (Jia vd., 2025). Medya ve eğlence sektöründe sinematik hava çekimleri, canlı etkinlik yayınları ve spor müsabakalarının görüntülenmesi için İHA'lar artık standart ve yaygın bir araç haline gelmiş bulunmaktadır (Soares vd., 2025). Güvenlik ve gözetleme alanında sınır kontrolü, kalabalık yönetimi ve kritik altyapı koruması için İHA sistemleri giderek artan oranda ve yaygın bir şekilde kullanılmaktadır. Askeri alanda ise keşif, istihbarat toplama, hedef belirleme ve hatta silahlı operasyonlar için çeşitli ölçek ve yeteneklerde farklı İHA platformları başarıyla geliştirilmekte ve aktif olarak kullanılmaktadır (Rinaldi, 2025).

Bu geniş ve çeşitli uygulama yelpazesi, İHA pazarında devasa bir büyümeye ve ekonomik genişlemeye yol açmıştır (Kumar, 2017). Federal Havacılık İdaresi (FAA) tarafından açıklanan verilere göre, yalnızca Amerika Birleşik Devletleri'nde 2016-2023 yılları arasında resmi olarak kayıtlı İHA sayısı yaklaşık 1,5 milyona ulaşarak %43,9'luk dikkat çekici bir bileşik yıllık büyüme oranı (CAGR) sergilemiştir (Rinaldi, 2025). Küresel ölçekte değerlendirildiğinde İHA pazarının 2030 yılına kadar 50 milyar dolarlık devasa bir hacme ulaşması öngörülmekte ve beklenmektedir (Aldossary vd., 2025). Ticari İHA pazarı yıllık %20'nin üzerinde istikrarlı bir büyüme gösterirken, tüketici segmenti de hobi ve rekreasyonel kullanım talepleriyle genişlemeye kesintisiz olarak devam etmektedir (Mälzer vd., 2025). Bu devasa büyüme trendi, İHA'ların ticari, endüstriyel ve bireysel kullanım alanlarındaki muazzam potansiyelini açıkça ortaya koymakla birlikte, beraberinde operasyonel güvenlik, hava sahası yönetimi ve uçuş güvenilirliği konularını kritik ve öncelikli bir gündem maddesi haline getirmiştir (Sonmezocak, 2025).

İHA platformlarının operasyonel başarısı ve güvenilirliği, sistemin çeşitli alt bileşenlerinin kusursuz ve uyumlu bir şekilde çalışmasına doğrudan bağlıdır (Makhtar vd., 2024). Bu bileşenler arasında tahrik sistemi (motorlar ve pervaneler), güç sistemi (bataryalar ve güç dağıtım kartları), aviyonik sistem (uçuş kontrolcüsü, sensörler ve iletişim modülleri), yapısal elemanlar (gövde, kollar ve iniş takımları) ve faydalı yük sistemleri (kameralar, sensörler vb.) yer almaktadır. Bu karmaşık ve birbirine bağımlı sistemlerden herhangi birinde meydana gelen bir arıza, görev başarısızlığından kontrol kaybına, ekonomik kayıplardan can güvenliği risklerine kadar geniş bir yelpazede ciddi ve olumsuz sonuçlara yol açabilmektedir. Özellikle kentsel alanlarda ve insan yoğunluğunun bulunduğu bölgelerde gerçekleştirilen operasyonlarda, olası bir kaza durumunda üçüncü şahıslara da zarar verebilmekte ve ciddi hukuki sorumluluklar doğurabilmektedir (Farajijalal vd., 2025).

Yapılan kapsamlı ve detaylı istatistiksel çalışmalar, İHA kazalarının nedenlerini sistematik olarak analiz etmiş ve son derece çarpıcı sonuçlar ortaya koymuştur. Bu araştırmalara göre İHA kazalarının yaklaşık %64'ü ekipman arızalarından kaynaklanmakta olup teknik sorunlar, insan hatasından çok daha yüksek bir kaza nedeni olarak belirgin şekilde öne çıkmaktadır (Zou vd., 2025). Ekipman arızaları arasında pervane hasarları, motor kusurları, batarya problemleri, sensör hataları ve yazılım aksaklıkları en yaygın görülen ve sıkça karşılaşılan sorunlardır (Soares vd., 2025). Araştırmalar ayrıca ticari bir İHA'nın her 100 ila 500 uçuş saatinde bir kritik düzeyde arıza yaşama olasılığının yüksek olduğunu açıkça göstermektedir; bu durum yoğun operasyonel kullanımda yaklaşık her 1-5 ayda bir potansiyel olarak ölümcül kaza riski anlamına gelmektedir (Kantue ve Pedro, 2022). Bu istatistikler, İHA sistemlerinde proaktif bakım uygulamalarının ve erken arıza tespitin ne denli kritik ve hayati olduğunu çok açık bir şekilde ortaya koymaktadır.

Bu bağlamda özellikle quadrotor gibi alt-belirlenmiş (underactuated) sistemlerde, itki kuvvetini ve dengeyi sağlayan pervaneler, en kritik ancak dış etkenlere karşı en savunmasız bileşenler olarak belirgin şekilde öne çıkmaktadır. Quadrotor sistemlerinde dört pervane, aracın havada kalması için gereken toplam kaldırma kuvvetini üretmekte, yatay hareket için gerekli itki vektörlerini sağlamakta ve üç eksen etrafındaki rotasyonel hareketleri (roll, pitch, yaw) hassas bir şekilde kontrol etmektedir (L. Zhang vd., 2025). Her bir pervane, motorun dönüş hızına bağlı olarak farklı miktarda itki üretmekte ve dört pervanenin diferansiyel hız kontrolü ile aracın tüm hareket serbestlik dereceleri etkin bir

şekilde yönetilmektedir (Sonmezocak, 2025). Bu nedenle, tek bir pervanede meydana gelen herhangi bir hasar bile sistemin tüm uçuş dinamiğini doğrudan ve anında etkilemekte ve ciddi kontrol sorunlarına yol açabilmektedir (Tong vd., 2021).

Yüksek hızlarda dönen pervaneler, operasyonel yaşam döngüleri boyunca çeşitli hasar mekanizmalarına ve tehlike faktörlerine maruz kalmaktadır. Uçuş sırasında kuş çarpmaları, özellikle düşük irtifalarda ve kuş göç yolları üzerinde gerçekleştirilen operasyonlarda önemli ve ciddi bir risk faktörü oluşturmaktadır (May ve Strohbach, 2025). Ağaç dalları, bina köşeleri, elektrik telleri ve diğer çevresel engellerle temas, özellikle dar alanlarda ve karmaşık ortamlarda manevra yapılırken sıkça karşılaşılan ve yaygın bir hasar nedenidir (W. Zhang vd., 2025). Sert iniş ve kalkışlar sırasında zemin teması, pervane uçlarında kırılma ve kalıcı deformasyona yol açabilmektedir. Malzeme yorulması, tekrarlanan mekanik stresler altında pervane yapısında mikro çatlakların oluşmasına ve bu çatlakların zamanla büyümesine neden olmaktadır (Kalay ve Özkul, 2024). Kompozit malzemelerde delaminasyon (tabaka ayrılması), pervane performansını ciddi şekilde düşürebilmekte ve yapısal bütünlüğü tehlikeye atabilmektedir (Bardis vd., 2025). Buzlanma koşullarında pervane yüzeyinde buz birikimi, hem aerodinamik profili bozmakta hem de kütle dengesizliğine yol açmaktadır (J. Wang vd., 2025). Ultraviyole ışınlarla uzun süreli maruz kalma ise polimer bazlı pervane malzemelerinde bozunmaya ve yapısal zayıflamaya neden olabilmektedir (Tiruvankadam vd., 2024).

Literatürde tanımlanan pervane hasar türleri çeşitli kategorilerde sistematik olarak sınıflandırılmaktadır. Yüzeysel hasarlar arasında çizikler, aşınmalar ve kaplama bozulmaları yer almakta olup bunlar genellikle aerodinamik verimliliği düşürmekle birlikte acil bir güvenlik riski oluşturmamaktadır. Yapısal hasarlar ise çatlaklar, kırık uçlar, eğilmeler ve kopan parçalar şeklinde kendini göstermekte ve uçuş güvenliğini doğrudan ve ciddi şekilde tehdit etmektedir. Kütle dengesizliği, pervane kanatlarından birinin hasar görmesi veya aşınması sonucu oluşan asimetric kütle dağılımı olup yoğun ve tehlikeli titreşimlere neden olmaktadır. Aerodinamik dengesizlik ise pervane profilinin bozulması sonucu her iki kanadın farklı miktarda itki üretmesi durumudur. Bu hasar türlerinin her biri, sistemde farklı semptomlar oluşturmakta ve kendine özgü karakteristik titreşim imzaları bırakmaktadır (Yaman, 2025).

Pervane hasarının uçuş dinamiği üzerindeki etkileri, fiziksel mekanizmaları açısından ayrıntılı ve kapsamlı olarak incelenmelidir. Hasarlı bir pervane, sağlam

halindekine kıyasla daha düşük itki üretmekte ve bu durum sistemde asimetric itki dağılımına yol açmaktadır. Örneğin, dört motorlu bir quadrotorda ön sağ pervanede hasar meydana geldiğinde, bu motor aynı devir sayısında daha az kaldırma kuvveti üretecektir. Uçuş kontrolcüsü bu dengesizliği algılayarak hasarlı motorun devir sayısını artırma yönünde tepki vermekte, ancak söz konusu kompanzasyon mekanizmasının başarısı sınırlı kalmaktadır. Asimetric itki dağılımı, yalpalama (yaw) ekseninde istenmeyen dönme momenti oluşturarak aracın yönelimini bozmakta ve kontrol güçlüğüne neden olmaktadır. Benzer şekilde, yunuslama (pitch) ve yuvarlanma (roll) eksenlerinde de moment dengesizlikleri ortaya çıkmakta ve aracın stabil uçuşunu tehlikeye atmaktadır (Yeom, 2025).

Hasarlı pervane, kütle dengesizliği nedeniyle döndüğünde periyodik bir merkezkaç kuvveti oluşturmakta ve bu kuvvet sisteme yoğun titreşimler olarak aktarılmaktadır. Titreşim frekansı, pervane dönüş hızının katları şeklinde ortaya çıkmakta ve kendine özgü karakteristik bir spektral imza oluşturmaktadır. Bu anormal titreşimler, sadece uçuş konforunu ve sensör okumalarının doğruluğunu etkilemekle kalmamakta, aynı zamanda gövde üzerinde rezonans etkilerine yol açarak ikincil ve zincirleme hasarlara neden olabilmektedir. Motor yatakları, sürekli titreşim altında hızlandırılmış aşınma ve erken ömür tükenmesi yaşayabilmektedir. Elektronik bileşenler, özellikle lehim bağlantıları ve konnektörler, titreşimden kaynaklanan mekanik streslerle gevşeyebilir veya tamamen kopabilir. Taşıyıcı kolların yapısal bütünlüğü, rezonans frekanslarına yakın titreşimler altında ciddi biçimde zarar görebilmektedir. Kamera ve gimbal sistemlerinde ise görüntü kalitesinde belirgin bozulmalar meydana gelmektedir (Okada vd., 2024).

Pervane hasarının bir diğer önemli ve kritik etkisi, sistem enerji tüketimindeki belirgin artıştır (Bartoszewski vd., 2024). Hasarlı pervane, aynı itki seviyesini üretmek için daha yüksek motor hızı gerektirmekte ve bu durum batarya tüketimini önemli ölçüde artırmaktadır (Ercan ve Dalkın, 2025). Uçuş kontrolcüsünün dengesizliği kompanse etme çabası, sürekli aktif düzeltme komutları üretmesine ve motorların optimum olmayan çalışma noktalarında çalışmasına neden olmaktadır. Araştırmalar, pervanelerdeki aerodinamik bozulmaların ve verim kayıplarının uçuş süresini (endurance) %18 ile %46 oranında kısaltabildiğini açıkça göstermiştir. Enerji tüketimindeki bu belirgin artış, özellikle uzun menzilli görevlerde ve enerji kritik uygulamalarda ciddi operasyonel kısıtlamalara ve görev başarısızlıklarına yol açabilmektedir (Dhulipalla, 2025).

Pervane hasarının bu denli kritik sonuçlar doğurabilmesine rağmen, geleneksel havacılıkta kullanılan bakım ve arıza tespit yöntemleri İHA teknolojisinin dinamik ve hızlı operasyonel gereksinimlerini karşılamakta giderek yetersiz kalmaktadır. Konvansiyonel yaklaşımda pervaneler, belirli uçuş saati aralıklarında veya takvim bazlı periyotlarda görsel denetime tabi tutulmakta ve şüpheli durumlarda değiştirilmektedir. Bu yöntem, yoğun iş gücü gerektiren, yüksek maliyetli ve ciddi zaman kayıplarına neden olan verimsiz bir süreçtir. Her uçuş öncesi kapsamlı bir görsel kontrol yapılması gerekliliği, operasyonel verimliliği önemli ölçüde düşürmektedir (Kishor vd., 2025). Daha da önemlisi, insan gözüne dayanan görsel denetimler sübjektif değerlendirmelere açık olup, denetçinin deneyimine, dikkat seviyesine, yorgunluk durumuna ve çevresel koşullara bağlı olarak farklı sonuçlar verebilmektedir (Plastropoulos vd., 2024).

Görsel denetimin en önemli kısıtlılıklarından biri, başlangıç aşamasındaki (incipient) hataları tespit etmekte başarısız olmasıdır (Kantue ve Pedro, 2022). Mikro düzeydeki çatlaklar, iç yapıdaki delaminasyonlar ve yüzey altı deformasyonları çıplak gözle görülememekte ve fark edilememektedir. Bu tür gizli hasarlar, görünür hale gelene kadar sessizce ilerleyebilmekte ve ancak kritik bir seviyeye ulaştığında fark edilebilmektedir. Bu durumda hasar çoğu zaman tamir edilemez düzeye ulaşmış olmakta ve pervane değişimi kaçınılmaz hale gelmektedir (H. Zhang vd., 2023). Daha tehlikeli senaryolarda ise hasar, uçuş sırasında ani ve beklenmedik bir kırılmaya dönüşerek felakete yol açabilmektedir. Ayrıca, İHA'ların zorlu iklim koşullarında, yüksek irtifalarda, uzak lokasyonlarda veya erişilmesi güç altyapılarda görev yapması, fiziksel erişim kısıtlılıkları nedeniyle düzenli manuel denetimi çoğu zaman imkânsız veya pratik olmaktan uzak kılmaktadır (Yang ve Mat, 2025).

Görsel denetimin sınırlamalarını aşmak için geliştirilen model tabanlı arıza tespit yaklaşımları, sistemin matematiksel modelini kullanarak beklenen davranış ile gerçek davranış arasındaki sapmaları analiz etmektedir. Bu yöntemde, İHA'nın aerodinamik katsayıları, kütle özellikleri, motor karakteristikleri ve kontrol dinamikleri içeren detaylı bir fiziksel model oluşturulmakta ve sensör ölçümleri bu modelin tahminleriyle karşılaştırılmaktadır (Yeom, 2025). Teorik olarak güçlü bir yaklaşım olmakla birlikte, model tabanlı yöntemler pratikte önemli ve zorlu uygulama güçlükleri barındırmaktadır (Okada vd., 2024). Doğru ve güvenilir bir modelin oluşturulması, kapsamlı sistem tanımlama deneyleri ve detaylı parametrik kalibrasyonlar gerektirmektedir. Sürtünme, kaldırma, sürüklenme gibi aerodinamik katsayıların gerçek zamanlı olarak kestirilmesi

hesaplama açısından yoğun ve kaynak tüketen bir süreçtir. Model parametreleri, çevresel koşullar (hava yoğunluğu, sıcaklık, rüzgâr vb.) ve sistem yaşlanması ile değişebilmekte, bu durum modelin sürekli güncellenmesini zorunlu kılmaktadır (Ezzara vd., 2025).

Literatür incelendiğinde, İHA hata tespiti üzerine yapılan çalışmaların büyük çoğunluğunun belirli kısıtlamalar altında gerçekleştirildiği görülmektedir. Araştırmaların önemli bir kısmı sadece pervane hasarlarına odaklanmış olup motor arızaları, yapısal gevşemeler, sensör hataları gibi diğer arıza modları yeterince ve kapsamlı şekilde ele alınmamıştır. Deneysel çalışmalar genellikle kontrollü laboratuvar koşullarında, sabit motor hızlarında veya sadece "hover" (havada asılı kalma) durumunda gerçekleştirilmiştir (Sonmezocak, 2025). Gerçek dünya koşullarındaki çevresel faktörler (rüzgâr, türbülans, sıcaklık değişimleri vb.) ve İHA'nın farklı hız seviyelerindeki dinamik davranışları çoğu zaman göz ardı edilmiştir. Rotor vidalarının veya taşıyıcı kol bağlantılarının gevşemesi gibi uçuş güvenliğini doğrudan tehlikeye atan yapısal hatalar literatürde yeterince ve detaylı şekilde ele alınmamıştır. Birçok modelin sınırlı veri setleriyle eğitilmesi ve farklı çevresel koşullarda genellenebilirlik sorunu yaşaması, bu alandaki araştırmaların odak noktasını daha sağlam ve adaptif modellere doğru kaydırmıştır (Islam vd., 2025).

Bu sınırlamalar, uçuş sırasında sistemin "sağlık durumunu" anlık olarak izleyebilen gerçek zamanlı ve otomatik arıza tespit sistemlerine olan ihtiyacı açıkça doğurmuştur. Modern İHA platformları üzerinde halihazırda bulunan Eylemsizlik Ölçüm Birimi (IMU) sensörleri, bu ihtiyacı karşılamak için ideal ve maliyet etkin bir veri kaynağı sunmaktadır. IMU, tipik olarak üç eksenli ivmeölçer (accelerometer) ve üç eksenli jiroskop (gyroscope) sensörlerinden oluşmakta ve bazı konfigürasyonlarda manyetometre de içerebilmektedir. İvmeölçerler, İHA gövdesinin x, y ve z eksenlerindeki doğrusal ivmelenmelerini ölçerken, jiroskoplar aynı eksenlerdeki açısal hızları hassas bir şekilde kaydetmektedir. Bu sensörler, uçuş kontrolü için zaten sistemde bulunduğu için, yapısal sağlık izleme amacıyla kullanılmaları ek donanım maliyeti gerektirmemekte ve bu durum önemli bir ekonomik avantaj sağlamaktadır.

IMU sensörlerinin yapısal sağlık izleme için değerli olmasının temel nedeni, mekanik arızaların sistemin titreşim profilinde karakteristik "imzalar" bırakmasıdır. Sağlıklı bir quadrotor sisteminde, dört pervanenin dengeli dönüşü düşük ve simetrik bir titreşim profili oluşturmaktadır. Pervane dengesizliği, motor yataklarındaki aşınma, vida

gevşemeleri veya yapısal çatlaklar gibi mekanik kusurlar, bu titreşim profilinde belirgin değişikliklere neden olmaktadır. Örneğin, hasarlı bir pervane döndüğünde oluşturduğu periyodik merkezkaç kuvveti, pervane dönüş frekansında (veya katlarında) karakteristik bir titreşim bileşeni yaratmaktadır (Cinoğlu, 2024). Motor yatak aşınması farklı bir frekans karakteristiği gösterirken, yapısal gevşemeler geniş bantlı titreşim artışına neden olabilmektedir. Bu titreşim sinyallerinin dikkatli analizi, arızanın varlığını, türünü ve şiddetini belirleme potansiyeli taşımaktadır (Koszewnik vd., 2025).

Ancak IMU sensörlerinden elde edilen titreşim sinyallerinin analizi, çeşitli teknik zorluklar ve karmaşık durumlar barındırmaktadır (Torres vd., 2025). Bu sinyaller yüksek boyutlu, gürültülü ve dinamik yapıdadır. Normal uçuş manevralarından kaynaklanan ivme ve açısal hız değişimleri, arıza kaynaklı titreşim bileşenleriyle iç içe geçmekte ve ayrıştırılmasını zorlaştırmaktadır (Gemayel vd., 2025). Çevresel faktörler (rüzgâr, türbülans vb.) de sinyal karakteristiğini etkilemekte ve analizi daha da karmaşık hale getirmektedir (Hale, 2022). Geleneksel eşikleme yöntemleri, sabit bir titreşim eşiği belirleyerek bu eşiğin aşılması durumunda alarm üretmekte, ancak bu yaklaşım farklı uçuş koşullarına ve arıza türlerine adapte olamamaktadır. Frekans analizi teknikleri (Fourier dönüşümü vb.) arızaya özgü frekans bileşenlerini ortaya çıkarabilmekte, ancak karmaşık ve değişken operasyonel koşullarda güvenilir sınıflandırma yapamamaktadır. Bu kısıtlamalar, daha sofistike ve gelişmiş veri analizi yaklaşımlarına olan ihtiyacı açıkça ortaya koymaktadır.

Teknolojideki son kırılma noktası olan Makine Öğrenmesi (MÖ) ve Derin Öğrenme (DÖ) algoritmaları, bu karmaşık verilerden otomatik özellik çıkarımı yaparak hataları yüksek hassasiyetle sınıflandırabilme yeteneği sunmaktadır. Geleneksel kural tabanlı sistemlerin aksine, makine öğrenmesi algoritmaları veriden öğrenme prensibiyle çalışmakta ve açıkça programlanmadan karmaşık örüntüleri tanıyabilmektedir (Nethamba ve Grobbelaar, 2023). Bu algoritmalar, yüksek boyutlu verilerden otomatik olarak ayırt edici özellikler çıkarabilmekte, farklı arıza modları arasında ince ve hassas ayrımlar yapabilmekte ve hataları henüz kritik bir seviyeye ulaşmadan erken aşamada teşhis edebilmektedir (Soares vd., 2025). Makine öğrenmesi tabanlı yaklaşımlar, sistemin normal davranış kalıplarını öğrenerek sapmaları tespit etmekte ve bu sayede önceden tanımlanmamış arıza türlerini bile yakalayabilme potansiyeline sahip olmaktadır.

Literatürde İHA arıza tespiti için çeşitli makine öğrenmesi algoritmaları başarıyla uygulanmıştır. Destek Vektör Makineleri (SVM), yüksek boyutlu özellik uzaylarında optimal ayırıcı hiper-düzlemler olarak sınıflandırma yapmakta ve özellikle küçük veri setlerinde etkili sonuçlar vermektedir. K-En Yakın Komşu (KNN) algoritması, özellik uzayında en yakın eğitim örneklerinin sınıflarına dayalı olarak tahmin yapmakta ve yorumlanabilirlik avantajı sunmaktadır. Karar Ağaçları (DT), hiyerarşik karar kuralları oluşturarak sınıflandırma yapmakta ve model kararlarının insan tarafından anlaşılabilir olması açısından değerlidir. Rastgele Orman (RF), çok sayıda karar ağacının birleştirilmesiyle oluşan topluluk öğrenmesi yöntemi olup aşırı öğrenmeye karşı dayanıklılık sağlamaktadır. Yapay Sinir Ağları (YSA), biyolojik sinir ağlarından esinlenen yapılarıyla karmaşık doğrusal olmayan ilişkileri başarıyla modelleyebilmektedir.

Derin öğrenme algoritmaları, özellikle zamansal ve mekânsal veri örüntülerinin analizinde üstün yetenekler sergilemektedir (Holdbrook, 2025). Evrişimli Sinir Ağları (CNN), ham sensör verilerinden veya spektrogramlardan otomatik özellik çıkarımı yapabilmekte ve elle tasarlanan özellik mühendisliği ihtiyacını ortadan kaldırmaktadır (Ali vd., 2025) (K. Wang vd., 2025). Uzun Kısa Süreli Bellek (LSTM) ağları, zamansal bağımlılıkları modelleyerek ardışık veri akışlarındaki örüntüleri başarıyla yakalayabilmektedir (Nayeem, 2025). Gated Recurrent Unit (GRU) yapıları, LSTM'e benzer yetenekleri daha az parametre ile sunmakta ve hesaplama verimliliği sağlamaktadır (Tunio vd., 2025). Bu derin öğrenme mimarileri, titreşim sinyallerindeki hem mekânsal hem de zamansal değişimleri analiz ederek gerçek zamanlı izleme sistemlerinde üstün performans sergilemektedir. Özellikle 1 saniyenin altındaki zaman pencerelerinde bile yüksek doğrulukla arıza tespiti yapabilmeleri, bu yaklaşımların gerçek zamanlı uygulamalar için uygunluğunu açıkça göstermektedir.

Makine öğrenmesi tabanlı akıllı tanı sistemlerinin en büyük avantajlarından biri, İHA'ya ek donanım yükü getirmeden mevcut sensörlerle çalışabilmesidir. IMU sensörleri zaten uçuş kontrolü için sistemde bulunduğu için yazılım tabanlı bir çözüm ek ağırlık, enerji tüketimi veya maliyet gerektirmemektedir. Bu durum hem ekonomik tasarruf sağlamak hem de aracın faydalı yük kapasitesini etkilememektedir. Ayrıca, bu sistemlerin Raspberry Pi, NVIDIA Jetson veya FPGA gibi gömülü platformlara entegre edilebilmesi, uçuş sırasında milisaniyeler düzeyinde karar verilmesine olanak tanımaktadır. Böylece, bir pervane hasarı tespit edildiğinde sistem otomatik olarak hata

toleranslı kontrol (FTC) mekanizmalarını tetikleyebilmekte, güvenli iniş protokollerini başlatabilmekte veya kalan motorların hızını optimize ederek kaza riskini önemli ölçüde minimize edebilmektedir.

Hata toleranslı kontrol mekanizmaları, arıza tespitinin pratik değerini artıran kritik bir bileşendir. Bir pervane hasarı tespit edildiğinde, sistemin bu bilgiyi kullanarak uygun ve orantılı bir tepki vermesi gerekmektedir (W. Zhang vd., 2025). Hafif hasar durumlarında, uçuş kontrolcüsü parametrelerinin yeniden ayarlanması ile görevin sürdürülmesi mümkün olabilmektedir (Pandya, 2025). Orta düzey hasarlarda, görevin kısaltılması ve en yakın güvenli iniş noktasına yönlendirilmesi tercih edilebilmektedir. Ağır hasar durumlarında ise acil iniş protokollerinin derhal devreye girmesi gerekmektedir. Bu karar mekanizmasının doğru çalışması, hasar seviyesinin güvenilir şekilde tespit edilmesine bağlıdır. Makine öğrenmesi modelleri, sadece hasarın varlığını değil, aynı zamanda şiddetini de sınıflandırabilmekte ve bu sayede orantılı tepki stratejilerinin uygulanmasına olanak tanımaktadır.

Tüm bu gelişmeler ve literatürdeki mevcut boşluklar ışığında, bu çalışmanın temel amacı gerçek dünya operasyonel koşullarında farklı hız seviyelerinde ve uçuş modlarında pervane hasarlarını tespit edebilen düşük maliyetli ve yüksek hassasiyetli bir sağlık izleme sistemi geliştirmektir. Çalışma kapsamında, bir quadrotor İHA platformunda meydana gelebilecek pervane hasarları, Cube Orange uçuş kontrolcüsü üzerindeki IMU sensörlerinden elde edilen titreşim sinyalleri üzerinden makine öğrenmesi algoritmalarıyla analiz edilmektedir. Deneysel çalışmalar, kontrollü laboratuvar ortamı yerine gerçek açık alan koşullarında ve otonom uçuş modunda gerçekleştirilmiştir. Bu yaklaşım, laboratuvar ortamının sınırlılıklarını aşarak gerçek operasyonel koşullarda sistemin performansını değerlendirme imkânı sunmaktadır.

Araştırmada, karmaşık titreşim sinyalleri Hızlı Fourier Dönüşümü (FFT) ile analiz edilmiş ve hesaplama maliyetini düşürmek amacıyla tüm spektral yapı kolektif olarak değerlendirilmiştir. Ham sensör verilerinden 255 adet özellik çıkarılmış olup bu özellikler istatistiksel metrikler, frekans domain özellikleri, motor dengesizlik göstergeleri ve tutum hata metrikleri kategorilerinde gruplandırılmıştır. Özellik çıkarımında kayan pencere (sliding window) yöntemi kullanılarak zamansal bağlamın korunması sağlanmıştır. Hata tespiti için Destek Vektör Makineleri (SVM), K-En Yakın Komşu (KNN), Karar Ağaçları (DT) ve Rastgele Orman (RF) gibi makine öğrenmesi

algoritmalarının performansları sistematik olarak karşılaştırılmıştır. Her algoritma için Grid Search yöntemiyle hiperparametre optimizasyonu gerçekleştirilmiş ve çapraz doğrulama ile model güvenilirliği değerlendirilmiştir.

Deneyisel çalışmalarda dört farklı hasar seviyesi (hasarsız, hafif, orta ve ağır) tanımlanmış ve her seviyede iki farklı uçuş senaryosu (dairese ve sekiz rotası) uygulanmıştır. Hasar seviyeleri, pervane yarıçapının sırasıyla %0, %3, %6 ve %8'ine karşılık gelen kümülatif kesimlerle oluşturulmuştur. Bu kademeli hasar yaklaşımı, hasarın etkilerinin artan şiddetle nasıl değiştiğinin anlaşılmasına olanak tanımaktadır. Tüm uçuşlar GPS destekli otonom mod (Auto) kullanılarak önceden tanımlanmış waypoint'ler takip edilerek gerçekleştirilmiş, bu sayede pilot müdahalesinden kaynaklanan varyasyonlar elimine edilmiştir. Toplam 8.261 örnek içeren veri seti, yaklaşık 108 Hz örnekleme frekansında kaydedilmiştir.

Bu çalışmanın özgün değeri birkaç temel noktada öne çıkmaktadır. İlk olarak, deneyler kontrollü laboratuvar ortamı yerine gerçek açık alan koşullarında gerçekleştirilmiş olup rüzgâr, sıcaklık değişimleri ve GPS sinyal kalitesi gibi çevresel faktörlerin etkisi altında sistem performansı değerlendirilmiştir. İkinci olarak, sabit hover durumu yerine dinamik uçuş senaryoları kullanılarak farklı manevra koşullarında (dönüşler, ivmelenmeler, yön değişiklikleri) veriler toplanmıştır. Bu yaklaşım, gerçek operasyonel kullanıma çok daha yakın bir test ortamı sağlamaktadır. Üçüncü olarak, önerilen model düşük işlemci gücüne sahip gömülü sistemlerde gerçek zamanlı çalışabilecek şekilde optimize edilmiştir. Derin öğrenme modelleri yerine geleneksel makine öğrenmesi algoritmalarının tercih edilmesi, hesaplama verimliliği ve yorumlanabilirlik avantajları sunmaktadır.

Çalışmanın pratik katkıları da önem taşımaktadır. Geliştirilen sistem, İHA üzerinde ek donanım yükü yaratmadan mevcut MEMS tabanlı ivmeölçer ve jiroskop sensörlerinden gelen titreşim verilerini kullanmaktadır. Model dosya boyutu ve bellek kullanımı, yaygın uçuş kontrolcülerinin kapasiteleri dahilinde kalmaktadır. Örnek başına tahmin süresi, örnekleme periyodunun çok altında olup gerçek zamanlı çalışmaya uygundur. Bu özellikler, sistemin mevcut İHA platformlarına minimum modifikasyonla entegre edilebilmesini mümkün kılmaktadır. Ayrıca, çalışma kapsamında oluşturulan veri seti ve geliştirilen yazılım altyapısı, gelecekteki araştırmalar için bir temel oluşturmaktadır.

Sonu olarak bu tez alıřması, İHA platformlarında pervane hasar tespiti iin makine ğrenmesi tabanlı bir yaklaşım sunarak, operasyonel güvenlięi artıracak düşük maliyetli ve yüksek performanslı bir izleme sistemi önermeyi hedeflemektedir. alıřmanın bulguları, hem akademik literatüre katkı sağlamayı hem de İHA endüstrisinde güvenilir ve uygulanabilir bir özüm ortaya koymayı amaçlamaktadır. İzleyen bölümlerde sırasıyla materyal ve yöntemler detaylandırılacak, deneysel bulgular sunulacak ve sonuçlar tartışılarak gelecek alıřmalar iin öneriler geliştirilecektir.



2. MATERYAL VE YÖNTEM

Bu bölümde, insansız hava aracı (İHA) pervane hasar tespiti için geliştirilen deneysel sistem ve yöntemler detaylı olarak açıklanmaktadır. Çalışmada kullanılan İHA platformu, deney düzeneği, veri toplama prosedürleri, pervane hasar protokolü, veri ön işleme aşamaları ve makine öğrenmesi modelleri sistematik bir şekilde sunulmaktadır.

2.1. İnsansız Hava Aracı Platformu

Bu çalışmada kullanılan İHA platformu, dört rotorlu (quadcopter) bir konfigürasyona sahiptir. Platform, 550 mm köşegen uzunluğunda bir frame yapısı üzerine inşa edilmiştir. Bu boyut, hem taşıma kapasitesi hem de manevra kabiliyeti açısından dengeli bir performans sunmaktadır.

Tahrik sistemi olarak dört adet Sunnysky X2216-10KV fırçasız DC (BLDC) motor kullanılmıştır. Bu motorlar, yüksek verimlilik ve düşük ağırlık özellikleri ile quadcopter uygulamaları için yaygın olarak tercih edilmektedir. Motorlara bağlı pervane çapı 10 inç (254 mm) olup kompozit malzemeden üretilmiştir. Kompozit pervaneler, hafiflik ve dayanıklılık açısından avantaj sağlamakta ancak darbe sonrası kırılğan davranış sergileyebilmektedir.

Güç kaynağı olarak 3S (11,1V nominal) LiPo batarya tercih edilmiş olup 10.000 mAh kapasiteye sahiptir. Bu kapasite, yaklaşık 15-20 dakikalık uçuş süresi sağlamaktadır. Platformun toplam ağırlığı batarya dahil yaklaşık 2000 gram olarak ölçülmüştür.

Uçuş kontrolcüsü olarak ArduPilot firmware yüklü Cube Orange kullanılmıştır. Cube Orange, yüksek hassasiyetli IMU sensörleri (üç eksenli ivmeölçer ve jiroskop) içermekte olup ArduPilot firmware ile çalışmaktadır. Kontrolcü, entegre barometre ve harici GPS modülü ile donatılmıştır. Sistem, GPS destekli otonom uçuş yapabilme kabiliyetine sahip olup yüksek hassasiyetli veri kaydı (~108 Hz) yapabilmektedir.

Motor konfigürasyonu X düzeninde olup motor numaralandırması standart ArduPilot konvansiyonuna uygundur. Motor 1 ön sağ konumda, Motor 2 arka sol konumda, Motor 3 ön sol konumda ve Motor 4 arka sağ konumda yer almaktadır. Bu çalışmada tüm hasar testleri Motor 1 pervanesinin tek kanadı üzerinde gerçekleştirilmiştir. İHA platformunun teknik özellikleri Çizelge 2.1'de özetlenmektedir.

Çizelge 2.1. İHA platformu teknik özellikleri

Özellik	Değer
Platform Tipi	Quadcopter (4 motorlu)
Frame Boyutu	550 mm (köşegen)
Motor Tipi	Brushless DC (BLDC)
Motor Modeli	Sunnysky X2216-10KV
Motor Sayısı	4 adet
Pervane Boyutu	10 inç (25,4 cm)
Pervane Malzemesi	Kompozit
Batarya	3S LiPo, 10.000 mAh
Toplam Ağırlık	2000 gram
Uçuş Kontrolcüsü	Cube Orange (ArduPilot)
IMU Sensörü	Cube Orange entegre IMU
GPS	Harici GPS modülü



Şekil 2.1. Çalışmada kullanılan 550 mm quadcopter İHA platformu. İHA, Sunnysky X2216-10KV motorlar ve 10 inç kompozit pervaneler ile donatılmıştır. Cube Orange uçuş kontrolcüsü merkezi konumda yerleştirilmiştir.

2.2. Deney Düzeneği ve Test Ortamı

Deneyisel çalışmalar, kontrollü açık alan koşullarında gerçekleştirilmiştir. Test ortamı ve uçuş parametreleri bu bölümde detaylandırılmaktadır.

2.2.1. Test ortamı

Uçuş testleri Konya ilinde bir yükseköğretim kurumu kampüs bahçesinde açık alanda gerçekleştirilmiştir. Test sahası, engelsiz ve düz bir alan olup GPS sinyalinin optimum düzeyde alınmasına olanak sağlamaktadır. Testler sırasında hava koşulları sakın olup rüzgar hızı 5 m/s'nin altında tutulmuştur. Bu koşul, rüzgarın uçuş verilerine olan etkisini minimize etmek ve pervane hasarından kaynaklanan değişimlerin daha net gözlemlenmesini sağlamak amacıyla belirlenmiştir.

Tüm uçuşlar Auto (otonom waypoint takibi) modunda gerçekleştirilmiştir. Bu mod, İHA'nın önceden tanımlanmış GPS koordinatlarını takip etmesini sağlamak ve pilot müdahalesinden kaynaklanan varyasyonları elimine etmektedir. Otonom uçuş modu, tekrarlanabilir ve karşılaştırılabilir veri toplama imkanı sunmaktadır.



Şekil 2.2. Konya'da bir yükseköğretim kurumu kampüs bahçesinde gerçekleştirilen uçuş testlerinden bir görünüm. İHA, otonom mod (Auto) kullanılarak önceden tanımlanmış GPS waypoint'lerini takip etmektedir.

2.2.2. Uçuş parametreleri

İHA uçuşları standartlaştırılmış parametreler ile gerçekleştirilmiştir. Uçuş yüksekliği barometrik ölçüme göre ortalama 9-10 metre olarak ayarlanmıştır. Bu yükseklik, hem güvenlik açısından yeterli marjı sağlamak hem de yer etkisinden (ground effect) uzak kalarak temiz aerodinamik veri elde edilmesine olanak tanımaktadır.

GPS uydu sayısı ortalama 31-32 uydu olarak kaydedilmiş olup bu değer yüksek konum hassasiyetini garanti etmektedir. Örnekleme frekansı yaklaşık 108 Hz olarak ayarlanmıştır. Bu çalışmada öznitelikler, pervane hasarının uçuş dinamiğine yansıyan ve 1–20 Hz bandında yer alan düşük frekanslı etkilerden çıkarılmaktadır. Bu nedenle 108 Hz örnekleme hızı, ilgili bandı güvenli bir marjla kapsamak için yeterli görülmüştür. Ortalama uçuş süresi O senaryosu için yaklaşık 83 saniye, 8 senaryosu için yaklaşık 124 saniye olarak gerçekleşmiştir. Toplam test süresi tüm uçuşlar dahil 825,3 saniye (yaklaşık 13,8 dakika) olarak hesaplanmıştır.

Her uçuş öncesinde standart bir ön kontrol prosedürü uygulanmıştır. Bu prosedür kapsamında İHA'nın kalibrasyonu yapılmış, GPS sinyalinin yeterli seviyede olduğu (>10 uydu) doğrulanmış ve motor testleri gerçekleştirilmiştir. Bu ön kontroller, veri kalitesinin tutarlılığını sağlamak için kritik öneme sahiptir.

2.2.3. Uçuş senaryoları

Veri toplama sürecinde iki farklı uçuş senaryosu kullanılmıştır. Bu senaryolar, İHA'nın farklı dinamik hareketler yapmasını gerektirdiğinden pervane hasarının etkilerinin çeşitli koşullarda gözlemlenmesini sağlamıştır.

O Senaryosu (Oval/Dairesel): Bu senaryoda İHA, dairesel bir yörüngede (O harfi şeklinde) otonom olarak uçurulmuştur. Daha sabit dönüş yarıçapı içermektedir. Veri setinin %40'ını oluşturmaktadır (3.306 örnek).

8 Senaryosu (Sonsuz/Sekiz): Bu senaryoda İHA, sekiz rakamı (∞) şeklinde bir uçuş rotası takip etmektedir. Sürekli yön değişikliği ve eğim açısı varyasyonları içermektedir. Veri setinin %60'ını oluşturmaktadır (4.955 örnek).

Her iki senaryo da önceden tanımlanmış GPS waypoint'leri kullanılarak Auto modda gerçekleştirilmiştir. Sekiz senaryosu daha karmaşık dinamik hareketler (keskin dönüşler, ivmelenme, yön değiştirme) içerdiğinden pervane hasarının etkilerinin daha belirgin şekilde ortaya çıkmasını sağlamıştır. Her hasar seviyesinde her iki senaryo ayrı ayrı test edilmiş olup toplamda 8 uçuş verisi (4 hasar seviyesi $\times$ 2 senaryo) toplanmıştır.

2.3. Pervane Hasar Protokolü

Pervane hasarı, gerçek dünya senaryolarını simüle etmek amacıyla kontrollü ve kademeli bir şekilde uygulanmıştır. Bu bölümde hasar verme yöntemi ve tanımlanan hasar seviyeleri açıklanmaktadır.

2.3.1. Hasar verme yöntemi

Pervane hasarı, kontrollü bir şekilde ön sağ pervaneye (Motor 1) uygulanmıştır. Motor 1'in seçilmesinin nedeni, bu motorun X konfigürasyonunda hem roll hem de pitch eksenlerini etkileyen kritik bir konumda bulunmasıdır. Hasar, pervanenin tek kanadının uç kısmından makas kullanılarak kademeli olarak verilmiştir. Tek kanat üzerinde hasar oluşturulması, asimetrik kütle dağılımı ve aerodinamik dengesizlik yaratarak gerçek dünya hasar senaryolarını daha iyi temsil etmektedir.

Kesim işlemi, dijital kumpas ile hassas ölçümler alınarak gerçekleştirilmiştir. Her kesim sonrasında kesim miktarı kaydedilmiş ve pervane tartılarak kütle değişimi doğrulanmıştır. Bu sistematik yaklaşım, hasar seviyelerinin tekrarlanabilir şekilde tanımlanmasını sağlamıştır.



Şekil 2.3. Pervaneye kontrollü hasar verme işlemi. Kesim miktarı dijital kumpas ile hassas şekilde ölçülmüştür.

2.3.2. Hasar seviyeleri

Dört farklı hasar seviyesi tanımlanmıştır. Her seviye, bir önceki seviyeye ek kesim yapılarak oluşturulmuştur. Pervane çapı 10 inç (254 mm), yarıçapı 127 mm olup hasar yüzdeleri pervane yarıçapına göre hesaplanmıştır.

Seviye 0 - Hasarsız (Baseline): Tüm pervaneler orijinal halinde olup herhangi bir kesim yapılmamıştır. Bu seviye, referans veri seti olarak kullanılmıştır. Toplam 2.116 örnek içermektedir.

Seviye 1 - Hafif Hasar: Motor 1 pervanesinin bir kanadının ucundan 3,88 mm kesim yapılmıştır. Pervane yarıçapının yaklaşık %3'üne karşılık gelen bu kesim, hafif bir dengesizlik oluşturmaktadır. Pervane fonksiyonelliği minimal düzeyde etkilenmiştir. Toplam 1.879 örnek içermektedir.


Seviye 2 - Orta Hasar: Seviye 1'e ek olarak 3,92 mm daha kesim yapılmıştır. Kümülatif toplam kesim miktarı 7,80 mm olup pervane yarıçapının yaklaşık %6'sına karşılık gelmektedir. Bu seviyede pervane dengesizliği belirgin hale gelmiştir. Toplam 2.120 örnek içermektedir.

Seviye 3 - Ağır Hasar: Seviye 2'ye ek olarak 2,20 mm daha kesim yapılmıştır. Kümülatif toplam kesim miktarı 10,00 mm olup pervane yarıçapının yaklaşık %8'ine karşılık gelmektedir. Bu seviyede pervane fonksiyonelliği ciddi şekilde etkilenmiş olup uçuş stabilitesi önemli ölçüde bozulmuştur. Toplam 2.146 örnek içermektedir.

Hasar seviyeleri Çizelge 2.2'de özetlenmektedir.

Çizelge 2.2. Pervane hasar seviyeleri

Seviye	Tanım	Kesim (mm)	Kümülatif (mm)	Yarıçap (%)	Örnek
0	Hasarsız	0	0	0	2.116
1	Hafif Hasar	3,88	3,88	~3	1.879
2	Orta Hasar	3,92	7,80	~6	2.120
3	Ağır Hasar	2,20	10,00	~8	2.146



Şekil 2.4. Pervane hasar seviyeleri bütüncül görünümü. Üstten alta: Hasarsız (0 mm), Hafif hasar (3,88 mm), Orta hasar (7,80 mm kümülatif), Ağır hasar (10,00 mm kümülatif).


2.4. Veri Toplama ve Kayıt

Bu bölümde veri toplama yöntemi, veri formatı ve veri seti özellikleri açıklanmaktadır.

2.4.1. Veri formatı ve kaynağı

Uçuş verileri, Cube Orange uçuş kontrolcüsünün dahili veri kayıt sistemi kullanılarak dataflash log (.bin) formatında kaydedilmiştir. Bu format, ArduPilot sistemlerinin standart yüksek çözünürlüklü veri kayıt formatıdır ve sensör verilerinin zaman damgalı olarak kaydedilmesini sağlamaktadır.

Kaydedilen .bin dosyaları, plot.ardupilot.org web arayüzü kullanılarak CSV (Comma-Separated Values) formatına dönüştürülmüştür. Bu dönüşüm, verilerin Python tabanlı analiz araçları ile işlenebilmesini sağlamıştır. CSV formatı, veri manipülasyonu ve makine öğrenmesi kütüphaneleri ile uyumluluk açısından tercih edilmiştir.



Şekil 2.5. ArduPilot plot.ardupilot.org web arayüzü. Dataflash log dosyaları bu arayüz kullanılarak CSV formatına dönüştürülmüştür.

2.4.2. Veri seti özellikleri

Toplanan veri seti, 8 ayrı uçuş dosyasından oluşmaktadır. Veri setinin genel özellikleri Çizelge 2.3'te özetlenmektedir.

Çizelge 2.3. Veri seti genel özellikleri

Parametre	Değer
Toplam Ham Örnek	8.261
Toplam Özellik (Ham)	35
Toplam Veri Boyutu	2,21 MB
Dosya Sayısı	8
Eksik Değer	10 (%0,0035)
Tekrar Eden Satır	0

Her uçuş dosyasının detaylı özellikleri Çizelge 2.4'te verilmektedir.

Çizelge 2.4. Uçuş dosyaları detaylı özellikleri

Dosya	Örnek	Özellik	Boyut	Eksik	Tamlık
Hasarsız 8.csv	1.304	35	0,35 MB	0	%100
Hasarsız O.csv	812	35	0,22 MB	0	%100
İlk Hasar 8.csv	1.113	35	0,30 MB	0	%100
İlk Hasar O.csv	766	35	0,20 MB	0	%100
İkinci Hasar 8.csv	1.219	35	0,33 MB	0	%100
İkinci Hasar O.csv	901	35	0,24 MB	0	%100
Üçüncü Hasar 8.csv	1.319	35	0,35 MB	10	%99,98
Üçüncü Hasar O.csv	827	35	0,22 MB	0	%100



Şekil 2.6. Veri seti sınıf dağılımı ve uçuş deseni dağılımı. Hasar seviyeleri dengeli dağılım göstermekte olup 8 senaryosu veri setinin %60'ını oluşturmaktadır.

2.5. Sensör Parametreleri

Veri setinde 10 farklı sensör grubundan toplam 35 parametre kaydedilmiştir. Sensör grupları ve ilgili parametreler Çizelge 2.5'te özetlenmektedir.

Çizelge 2.5. Sensör grupları ve kanal sayıları

Sensör	Kanal	Parametreler
IMU[2]	6	AccX, AccY, AccZ, GyrX, GyrY, GyrZ
ATT	6	Roll, Pitch, Yaw, DesRoll, DesPitch, DesYaw
VIBE[0]	3	VibeX, VibeY, VibeZ
RCOU	4	C1, C2, C3, C4 (Motor PWM)
BAT[0]	4	Curr, Volt, CurrTot, VoltR
GPS[0]	3	Alt, NSats, HDop
BARO[0]	1	Alt
PID (P/R)	6	PIDP.P/I/D, PIDR.P/I/D
CTUN	1	ThO (Throttle Output)
timestamp	1	timestamp(ms)

2.5.1. Kaydedilen sensör verileri

Her uçuş için aşağıdaki sensör verileri yüksek frekansta (~108 Hz) kaydedilmiştir:

IMU (Inertial Measurement Unit) Verileri: İvmeölçer (Accelerometer) verileri AccX, AccY, AccZ olarak m/s^2 biriminde ve jiroskop (Gyroscope) verileri GyrX, GyrY, GyrZ olarak rad/s biriminde kaydedilmiştir. IMU verileri, İHA'nın anlık ivme ve açısal hız değişimlerini yakalamakta olup pervane hasarının dinamik etkilerini tespit etmek için kritik öneme sahiptir.

Motor ve Kontrol Verileri: Motor PWM sinyalleri RCOU.C1, C2, C3, C4 olarak kaydedilmiştir. PWM değerleri, her motorun o anlık gaz seviyesini temsil etmektedir. Motor akımı BAT[0].Curr olarak Amper, batarya voltajı BAT[0].Volt olarak Volt biriminde kaydedilmiştir.

Titreşim Verileri: Titreşim seviyeleri VIBE[0].VibeX, VibeY, VibeZ olarak kaydedilmiştir. Titreşim verileri, pervane dengesizliğinin en doğrudan göstergesi olup hasar tespiti için en ayırt edici özellikler arasındadır.

Attitude (Duruş) Verileri: Roll, Pitch, Yaw açıları ve bunların hedef değerleri (DesRoll, DesPitch, DesYaw) kaydedilmiştir. Gerçek değerler ile hedef değerler

arasındaki fark, uçuş kontrolcüsünün pervane hasarını kompanse etme çabasını yansıtmaktadır.


GPS ve Barometre Verileri: GPS yüksekliği GPS[0].Alt olarak metre, barometrik yükseklik BARO[0].Alt olarak metre biriminde kaydedilmiştir. GPS uydu sayısı GPS[0].NSats ve GPS doğruluk değeri GPS[0].HDop parametreleri de kaydedilmiştir.

PID Kontrol Parametreleri: Roll ve Pitch eksenleri için PID kontrol değerleri (P, I, D bileşenleri) kaydedilmiştir. Bu parametreler, uçuş kontrolcüsünün stabilizasyon algoritmasının tepkilerini göstermektedir.

Kritik sensör parametrelerinin istatistiksel özeti Çizelge 2.6'da verilmektedir.

Çizelge 2.6. Kritik sensör parametreleri istatistikleri

Sensör	Min	Max	Ort $\pm$ Std	Skew	Kurt
IMU[2].AccX (m/s ²)	-4,06	5,19	-0,19 $\pm$ 0,36	0,19	13,50
IMU[2].AccY (m/s ²)	-4,59	2,99	-0,01 $\pm$ 0,43	-0,77	8,21
IMU[2].AccZ (m/s ²)	-28,55	-3,90	-9,80 $\pm$ 0,89	-1,65	29,22
VIBE[0].VibeX	0,01	29,70	7,80 $\pm$ 3,50	-0,37	0,11
VIBE[0].VibeY	0,01	25,54	7,17 $\pm$ 2,75	-0,59	2,98
VIBE[0].VibeZ	0,01	27,46	10,30 $\pm$ 3,91	-1,14	1,52
RCOU.C1 (PWM)	1100	1846	1579 $\pm$ 160	-2,16	3,85
RCOU.C3 (PWM)	1100	1860	1654 $\pm$ 178	-2,39	4,64
BAT[0].Curr (A)	0,00	16,85	9,51 $\pm$ 3,39	-1,98	3,21
BAT[0].Volt (V)	10,37	12,66	11,16 $\pm$ 0,44	0,49	-0,25



Şekil 2.7. Sensör sinyalleri zaman serisi örnekleri. Titreşim, motor PWM, ivmeölçer, jiroskop, attitude açıları ve batarya voltajı sinyalleri gösterilmektedir.

2.6. Veri Kalitesi Değerlendirmesi

Veri setinin kalite analizi yapılmış, eksik değerler ve aykırı değerler sistematik olarak tespit edilmiştir.

2.6.1. Eksik veri analizi

Toplam 10 eksik değer tespit edilmiş olup tamamı 'Üçüncü Hasar 8.csv' dosyasındadır. Bu eksik değerler 10 farklı sütunda birer adet olarak dağılmıştır: RCOU.C1-C4, VIBE.VibeX/Y/Z ve GPS.Alt/NSats/HDop. Eksik değer oranı %0,0035 olup ihmal edilebilir düzeydedir. Eksik değerler satır silme yöntemi ile işlenmiştir.

2.6.2. Aykırı değer analizi

Aykırı değerlerin tespiti için Interquartile Range (IQR) yöntemi kullanılmıştır. Bu yöntemde Q1 (birinci çeyrek) ve Q3 (üçüncü çeyrek) değerleri hesaplanarak $IQR = Q3 - Q1$ formülü ile çeyrekler arası aralık belirlenmektedir. Alt sınır $Q1 - 1,5 \times IQR$ ve üst sınır $Q3 + 1,5 \times IQR$ olarak tanımlanmış, bu sınırların dışındaki değerler aykırı olarak işaretlenmiştir (Ateş, 2022).

Toplam 5.046 aykırı değer tespit edilmiştir (%1,75). Aykırı değerlerin büyük çoğunluğu IMU jiroskop ve motor PWM kanallarında tespit edilmiştir. Aykırı değer analizi sonuçları Çizelge 2.7'de özetlenmektedir.

Çizelge 2.7. Aykırı değer analizi sonuçları (IQR yöntemi)

Sensör	Aykırı Sayısı	Toplam Değer	IQR Sınırları
IMU[2].AccX	163	8261	[-1,03; 0,64]
IMU[2].AccY	136	8261	[-1,07; 1,07]
IMU[2].AccZ	422	8261	[-11,53; -8,04]
IMU[2].GyrX	430	8261	[-0,23; 0,23]
IMU[2].GyrY	398	8261	[-0,22; 0,23]
IMU[2].GyrZ	839	8261	[-0,37; 0,41]
RCOU.C1	851	8260	[1442,5; 1790,5]
RCOU.C2	925	8260	[1489,5; 1757,5]
RCOU.C3	882	8260	[1546,5; 1854,5]



Şekil 2.8. Veri kalitesi değerlendirme grafiği. Veri tamlığı, tekrar eden satırlar, örnek sayısı dağılımı ve özellik bazlı aykırı değer sayıları gösterilmektedir.

2.7. Veri Ön İşleme

Ham sensör verileri doğrudan makine öğrenmesi modellerine uygulanamaz. Bu nedenle veriler sistematik bir ön işleme sürecinden geçirilmiştir. Bu süreç; veri

temizleme, normalizasyon, pencere tabanlı segmentasyon ve özellik çıkarımı aşamalarından oluşmaktadır. Veri işleme pipeline'ı Çizelge 2.8'de özetlenmektedir.

Çizelge 2.8. Veri işleme pipeline aşamaları

Aşama	Örnek	Özellik	İşlem
1. Ham Veri	8.260	35	CSV Yükleme
2. Ön İşleme	7.924 (-336)	59 (+24)	Temizlik + Türetme
3. Özellik Çıkarımı	384 pencere	255	Windowing

2.7.1. Aykırı değer tespiti ve temizleme

Aykırı değerlerin tespiti için Interquartile Range (IQR) yöntemi kullanılmıştır. Toplam 336 aykırı değer içeren satır tespit edilmiş ve veri setinden çıkarılmıştır. Bu değer, toplam verinin %4,07'sine karşılık gelmektedir. Aykırı değerlerin büyük çoğunluğu IMU jiroskop ve motor PWM kanallarında tespit edilmiştir. Aykırı değer temizliği, model performansını olumsuz etkileyebilecek ekstrem değerlerin elimine edilmesini sağlamıştır.

2.7.2. Pencere tabanlı özellik çıkarımı

Zaman serisi verilerinden anlamlı özellikler çıkarmak için kayan pencere (sliding window) yöntemi kullanılmıştır. Bu yöntemde veri, belirli uzunluktaki ardışık pencerelere bölünmekte ve her pencere için istatistiksel özellikler hesaplanmaktadır (Kılıç vd., 2025).

Pencere boyutu 40 örnek (yaklaşık 0,37 saniye @108Hz örnekleme frekansı) olarak belirlenmiştir. Adım boyutu 20 örnek olup %50 örtüşme sağlanmıştır. Toplam pencere sayısı 384 olarak hesaplanmış, bunlardan 307'si eğitim ve 77'si test için ayrılmıştır.

Pencere boyutu seçimi, pervane titreşim döngüsünün yeterli sayıda örneğini içerecek şekilde belirlenmiştir. %50 örtüşme oranı, veri kaybını minimize ederken hesaplama maliyetini dengede tutmaktadır. Bu yaklaşım, hem zamansal bağlamın korunmasını hem de yeterli sayıda eğitim örneği elde edilmesini sağlamıştır.

2.8. Özellik Mühendisliği

Özellik mühendisliği, ham sensör verilerinin makine öğrenmesi algoritmaları için anlamlı sayısal gösterimlere dönüştürülmesi sürecidir. Bu çalışmada her pencere için 255 özellik hesaplanmış olup bu özellikler dört ana kategoride gruplandırılmıştır.

2.8.1. İstatistiksel özellikler

Her sensör kanalı için 14 istatistiksel özellik hesaplanmıştır. Bunlar; ortalama (mean), standart sapma (std), maksimum (max), minimum (min), medyan (median), çarpıklık (skewness), basıklık (kurtosis), aralık (range), çeyrekler arası aralık (IQR), 90. yüzdelik (p90), 10. yüzdelik (p10), tepe-tepe değer (peak_to_peak), karekök ortalama (RMS) ve değişim katsayısı (CV) şeklindedir.

İstatistiksel özellikler, sinyalin merkezi eğilimini, dağılımını ve varyasyonunu karakterize etmektedir. Özellikle çarpıklık ve basıklık değerleri, sinyal dağılımının normalden sapmasını göstermekte ve hasar durumlarında belirgin değişimler sergilemektedir.

2.8.2. Motor dengesizlik özellikleri

Motor PWM değerlerinden türetilen bu özellikler, pervane hasarının motor kontrol sistemine olan etkisini yansıtmaktadır. Hesaplanan özellikler şunlardır: ortalama gaz (mean_throttle), dört motor arası standart sapma (balance_std), motorlar arası maksimum fark (balance_range), dengesizlik oranı (imbalance_ratio), çapraz motor farkları (diag1_diff: Motor1-Motor3, diag2_diff: Motor2-Motor4), ön-arka motor farkı (front_back_diff) ve sol-sağ motor farkı (left_right_diff).

Hasarlı pervane, ilgili motorun daha fazla PWM talebi oluşturmaya neden olmaktadır. Bu durum motor dengesizlik özelliklerinde sistematik değişimlere yol açmaktadır.

2.8.3. Frekans domain özellikleri

Hızlı Fourier Dönüşümü (FFT) kullanılarak zaman domain sinyalleri frekans domain'e aktarılmıştır. Her sensör kanalı için hesaplanan spektral özellikler şunlardır: baskın frekans (dominant_freq), baskın frekans genliği (dominant_mag), spektral kütle merkezi (spectral_centroid), düşük/orta/yüksek frekans bandı enerjileri (energy_low,


energy_mid, energy_high), toplam spektral enerji (total_energy) ve spektral entropi (entropy) (Kaya, 2025).

Frekans domain özellikleri, pervane titreşim karakteristiğindeki değişimleri yakalamaktadır. Hasarlı pervane, karakteristik titreşim frekansında kayma ve enerji dağılımında değişime neden olmaktadır.


2.8.4. Attitude hata özellikleri

Uçuş kontrolcüsünün hedef duruş açıları ile gerçek duruş açıları arasındaki farklar hesaplanmıştır. Roll hatası (Roll_Error = ATT.Roll - ATT.DesRoll) ve pitch hatası (Pitch_Error = ATT.Pitch - ATT.DesPitch) temel değişkenler olup bu değişkenlerin istatistiksel türevleri de özellik setine eklenmiştir.

Attitude hata özellikleri, uçuş kontrolcüsünün pervane hasarını kompanse etme çabasını yansıtmaktadır. Yüksek hata değerleri, kontrolcünün hedef konumu korumakta zorlandığını göstermektedir.



Şekil 2.9. Özellik dağılımları (hasar seviyelerine göre). Titreşim, motor PWM, ivme ve GPS yükseklik özelliklerinin histogram dağılımları gösterilmektedir.



Şekil 2.10. Sensör korelasyon matrisi. Titreşim eksenleri arasında ve motor kanalları arasında yüksek korelasyonlar gözlemlenmektedir.

2.9. Makine Öğrenmesi Modelleri

Bu çalışmada pervane hasar seviyesinin sınıflandırılması için altı farklı makine öğrenmesi algoritması değerlendirilmiştir. Algoritma seçiminde çeşitlilik, yorumlanabilirlik ve hesaplama verimliliği kriterleri göz önünde bulundurulmuştur. Seçilen algoritmalar hem parametrik hem de parametrik olmayan yöntemleri, hem doğrusal hem de doğrusal olmayan karar sınırlarını kapsamaktadır.

Sistemin makine öğrenmesi bileşenleri Python 3.x programlama dili kullanılarak geliştirilmiş olup, modüler bir yazılım mimarisi benimsenmiştir.

Makine öğrenmesi modelleri ve veri işleme süreçleri için aşağıdaki Python kütüphaneleri kullanılmıştır:

- NumPy (v1.24+): Sayısal hesaplamalar ve matris işlemleri için temel kütüphane
- Pandas (v2.0+): Veri manipülasyonu ve analizi için DataFrame yapıları
- Scikit-learn (v1.3+): Makine öğrenmesi algoritmaları, ön işleme ve model değerlendirme araçları
- SciPy (v1.11+): Sinyal işleme, Hızlı Fourier Dönüşümü (FFT) ve istatistiksel analizler
- Matplotlib ve Seaborn: Veri görselleştirme ve sonuç grafikleri
- Joblib: Eğitilmiş modellerin serileştirilmesi ve kaydedilmesi
- PyYAML: Yapılandırma dosyalarının (config.yaml) okunması ve yönetimi

2.9.1. K-en yakın komşu (KNN) algoritması

K-en yakın komşu (K-Nearest Neighbors, KNN) algoritması, örnek tabanlı öğrenme yöntemlerinden biridir. Bu algoritma, sınıflandırılacak yeni bir örneğin etiketini, özellik uzayında kendisine en yakın k adet eğitim örneğinin etiketlerinin çoğunluk oylamasıyla belirlemektedir (Balcıoğlu ve Sezen, 2024).

KNN'in temel avantajı, eğitim aşamasında herhangi bir model oluşturmaması ve tüm hesaplamaların tahmin aşamasında yapılmasıdır. Bu özellik, algoritmayı basit ve yorumlanabilir kılmaktadır. Öte yandan, yüksek boyutlu özellik uzaylarında ve büyük veri setlerinde tahmin süresi artmaktadır.

2.9.2. Karar ağacı (Decision Tree) algoritması

Karar ağacı algoritması, veriyi hiyerarşik bir ağaç yapısında organize ederek sınıflandırma yapmaktadır. Her düğüm bir özellik üzerinde test, her dal testin olası sonuçlarından birini ve her yaprak düğüm bir sınıf etiketini temsil etmektedir (Alshari vd., 2021).

Ağaç oluşturma sürecinde, her düğümde veriyi en iyi bölen özellik seçilmektedir. Bu seçim için Gini impurity kriteri kullanılmıştır. Gini impurity, bir düğümdeki örneklerin homojenliğini ölçmektedir; düşük Gini değeri yüksek homojenliği ifade etmektedir.

Karar ağaçlarının en önemli avantajı yüksek yorumlanabilirliktir. Ağaç yapısı görselleştirilerek model kararları insan tarafından anlaşılabilir hale gelmektedir. Ayrıca özellik önemi (feature importance) değerleri doğal olarak elde edilmektedir. Overfitting'i önlemek için ağaç derinliği optimize edilmiştir.

2.9.3. Rastgele orman (Random Forest) algoritması

Rastgele orman, çok sayıda karar ağacının bir araya getirilmesiyle oluşturulan bir topluluk (ensemble) öğrenme yöntemidir. Her ağaç, orijinal veri setinin bootstrap örnekleme üzerinde ve rastgele seçilen özellik alt kümeleri kullanılarak eğitilmektedir. Final tahmin, tüm ağaçların tahminlerinin çoğunluk oylamasıyla belirlenmektedir (Eng Lim ve Park, 2024).

Rastgele orman, tek karar ağacına göre daha düşük varyansa sahiptir ve overfitting'e karşı daha dayanıklıdır. Ayrıca özellik önemlerinin güvenilir bir şekilde hesaplanmasını sağlamaktadır.

2.9.4. Destek vektör makinesi (SVM) algoritması

Destek vektör makinesi (Support Vector Machine, SVM), sınıfları birbirinden ayıran optimal hiper-düzlemi bulmayı amaçlayan bir algoritmadır. Optimal hiper-düzlem, sınıflar arasındaki marjini (en yakın örneklere olan mesafeyi) maksimize eden düzlemdir (Li ve Zhang, 2024).

SVM'in gücü, çekirdek (kernel) fonksiyonları kullanarak doğrusal olmayan karar sınırları oluşturabilmesidir. Çekirdek fonksiyonu, veriyi yüksek boyutlu bir özellik uzayına dolaylı olarak dönüştürerek doğrusal ayrım yapılmasını sağlamaktadır.

Bu çalışmada iki farklı çekirdek fonksiyonu test edilmiştir. İlk olarak doğrusal çekirdek (linear kernel) kullanılmıştır. Doğrusal çekirdek, sınıflar arasında doğrusal bir hiper-düzlem aramaktadır. Düşük hesaplama maliyeti ve yüksek yorumlanabilirlik avantajlarına sahiptir. İkinci olarak radyal tabanlı fonksiyon çekirdeği (RBF kernel) kullanılmıştır. RBF çekirdeği, doğrusal olmayan karar sınırları oluşturabilmektedir.

2.9.5. Naive Bayes algoritması

Naive Bayes, Bayes teoremine dayanan olasılıksal bir sınıflandırma algoritmasıdır. 'Naive' (saf) sıfatı, algoritmanın tüm özelliklerin birbirinden bağımsız olduğunu varsaymasından gelmektedir. Bu varsayım çoğu gerçek dünya verisinde geçerli olmasa da, algoritma pratikte şaşırtıcı derecede iyi performans gösterebilmektedir (Al Ghozali vd., 2023).

Bu çalışmada Gaussian Naive Bayes kullanılmıştır. Bu varyant, sürekli özelliklerin her sınıf içinde normal (Gaussian) dağılıma sahip olduğunu varsaymaktadır. Naive Bayes'in avantajları arasında hızlı eğitim süresi, düşük bellek kullanımı ve küçük veri setlerinde bile çalışabilme yeteneği sayılabilir. Ancak özellikler arası korelasyonları yakalayamaması bir dezavantajdır.

2.9.6. Hiperparametre optimizasyonu

Model performansını maksimize etmek için tüm algoritmalar üzerinde sistematik bir hiperparametre optimizasyonu gerçekleştirilmiştir. Optimizasyon yöntemi olarak Grid Search (ızgara araması) kullanılmıştır. Grid Search, belirtilen parametre değerlerinin tüm kombinasyonlarını deneyerek en iyi performansı veren kombinasyonu bulmaktadır (Sungur ve Bakir, 2024).

Hiperparametre optimizasyonu sırasında her parametre kombinasyonu için 3-katlı çapraz doğrulama uygulanmıştır. Bu yaklaşım, hesaplama verimliliği ile güvenilirlik arasında denge sağlamaktadır. Performans değerlendirme metriği olarak ağırlıklı F1-skoru (f1_weighted) kullanılmıştır. Her algoritma için tanımlanan parametre arama uzayı Çizelge 2.9'da verilmektedir.

Çizelge 2.9. Hiperparametre arama uzayı

Algoritma	Parametre Arama Uzayı
KNN	n_neighbors: [3, 5, 7, 9], weights: [uniform, distance], metric: [euclidean, manhattan]
Karar Ağacı	max_depth: [5, 10, 15, 20, None], min_samples_split: [2, 5, 10], min_samples_leaf: [1, 2, 4], criterion: [gini, entropy]
Rastgele Orman	n_estimators: [50, 100, 200], max_depth: [5, 10, 15, None], min_samples_split: [2, 5, 10], min_samples_leaf: [1, 2, 4]
SVM (Linear)	C: [0,1, 1, 10, 100]
SVM (RBF)	C: [0,1, 1, 10, 100], gamma: [scale, auto, 0,1, 0,01]
Naive Bayes	var_smoothing: [1e-9, 1e-8, 1e-7, 1e-6]

Grid Search optimizasyonu sonucunda her algoritma için en iyi performansı veren parametre kombinasyonları belirlenmiş ve bu parametreler ile final modeller eğitilmiştir. Optimizasyon sürecinde toplam kombinasyon sayıları şu şekildedir: KNN için 16 ($4 \times 2 \times 2$), Karar Ağacı için 90 ($5 \times 3 \times 3 \times 2$), Rastgele Orman için 108 ($3 \times 4 \times 3 \times 3$), SVM Linear için 4, SVM RBF için 16 (4×4) ve Naive Bayes için 4 kombinasyon test edilmiştir.

2.9.7. Model doğrulama stratejisi

Model performansının güvenilir bir şekilde değerlendirilmesi için iki aşamalı bir doğrulama stratejisi uygulanmıştır.

Hiperparametre optimizasyonu aşamasında 3-katlı çapraz doğrulama kullanılmıştır. Bu aşamada amaç, yüzlerce parametre kombinasyonu arasından en iyi performansı vereni bulmaktır. Hesaplama verimliliği açısından 3-katlı doğrulama tercih edilmiştir, zira toplam 238 kombinasyon için her birinin 3 kez değerlendirilmesi 714 model eğitimi gerektirmektedir.

Final model değerlendirmesi aşamasında 5-katlı çapraz doğrulama (5-Fold CV) kullanılmıştır. En iyi hiperparametreler belirlendikten sonra, modelin gerçek performansının güvenilir bir şekilde tahmin edilmesi için daha fazla katlama sayısı tercih

edilmiştir. Veri bölünmesinde katmanlı örnekleme uygulanmış, bu sayede her katta sınıf oranları orijinal veri setindeki oranlara yakın tutulmuştur.

Ayrıca veri seti %80 eğitim ve %20 test olarak bölünerek hold-out değerlendirmesi de yapılmıştır. Bu bölünmede de katmanlı örnekleme uygulanmıştır. Çapraz doğrulama, modelin farklı veri alt kümelerindeki performansının tutarlılığını ölçmektedir. Düşük standart sapma değeri, modelin farklı verilerde tutarlı performans gösterdiğini ifade etmektedir.

2.9.8. Performans metrikleri

Model performansının çok boyutlu değerlendirilmesi için birden fazla metrik kullanılmıştır. Her metrik, modelin farklı bir yönünü değerlendirmektedir.

Doğruluk (Accuracy): Tüm tahminler içinde doğru tahminlerin oranını vermektedir. $Accuracy = (TP + TN) / (TP + TN + FP + FN)$ formülü ile hesaplanmaktadır. Bu metrik dengeli sınıf dağılımlarında genel performansın iyi bir göstergesidir.

Kesinlik (Precision): Pozitif tahmin edilenler içinde gerçekten pozitif olanların oranını vermektedir. $Precision = TP / (TP + FP)$ formülü ile hesaplanmaktadır. Yüksek kesinlik, false positive oranının düşük olduğunu göstermektedir.

Duyarlılık (Recall): Gerçek pozitiflerin ne kadarının doğru tespit edildiğini göstermektedir. $Recall = TP / (TP + FN)$ formülü ile hesaplanmaktadır. Yüksek duyarlılık, false negative oranının düşük olduğunu ifade etmektedir. Pervane hasarı tespitinde false negative (hasarın kaçırılması) kritik olduğundan recall metriği özel öneme sahiptir.

F1-skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır. $F1 = 2 \times (Precision \times Recall) / (Precision + Recall)$ formülü ile hesaplanmaktadır. F1-skoru, kesinlik ve duyarlılık arasındaki dengeyi tek bir sayıda özetlemektedir.

Çok sınıflı problemlerde bu metrikler makro ortalama (her sınıfa eşit ağırlık) veya ağırlıklı ortalama (sınıf frekansına göre ağırlık) olarak hesaplanabilmektedir. Bu çalışmada ağırlıklı ortalama (weighted average) kullanılmıştır. Hiperparametre optimizasyonunda da aynı şekilde ağırlıklı F1-skoru (f1_weighted) değerlendirme ölçütü olarak belirlenmiştir.

3. BULGULAR

Bu bölümde, geliştirilen makine öğrenmesi modellerinin performans sonuçları, karşılaştırmalı analizler ve elde edilen bulguların yorumları sunulmaktadır. Altı farklı algoritmanın dört sınıflı hasar seviyesi tahmini problemi üzerindeki başarıları çeşitli metriklerle değerlendirilmiştir. Test seti toplam 77 pencere örneği içermekte olup eğitim sürecinde hiç kullanılmamıştır.

3.1. Model Performans Karşılaştırması

Altı farklı makine öğrenmesi algoritmasının test seti üzerindeki performansları Çizelge 3.1'de sunulmuştur. Performans değerlendirmesinde doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skoru metrikleri kullanılmıştır. Her metrik, modelin farklı bir yönünü değerlendirmektedir: doğruluk genel başarıyı, kesinlik yanlış pozitif oranını, duyarlılık kaçırılan pozitif oranını ve F1-skoru kesinlik ile duyarlılık arasındaki dengeyi ifade etmektedir.


Çizelge 3.1. Model performans karşılaştırması (test seti, n=77)

Model	Doğruluk	Kesinlik	Duyarlılık	F1-Skor	Eğitim Doğ.
Karar Ağacı	0,9481	0,9475	0,9456	0,9476	1,0000
Rastgele Orman	0,9351	0,9456	0,9375	0,9349	1,0000
SVM (Doğrusal)	0,8701	0,8755	0,8701	0,8695	1,0000
SVM (RBF)	0,8571	0,8627	0,8571	0,8584	1,0000
KNN	0,8442	0,8436	0,8442	0,8396	1,0000
Naive Bayes	0,5455	0,5771	0,5559	0,5471	0,7590


Sonuçlar incelendiğinde, Karar Ağacı algoritmasının 0,9481 test doğruluğu ile en yüksek performansı gösterdiği görülmektedir. Bu değer, 77 test örneğinden 73'ünün doğru sınıflandırıldığı anlamına gelmektedir. Karar Ağacı'nın F1-skoru 0,9476 olarak hesaplanmış olup bu değer kesinlik ve duyarlılık arasındaki dengenin yüksek olduğunu göstermektedir.

Rastgele Orman algoritması %93,51 doğruluk ile ikinci sırada yer almıştır. Karar Ağacı'na yakın performans sergilemesi, tek bir iyi yapılandırılmış ağacın bu problem için yeterli olduğunu düşündürmektedir. Topluluk öğrenmesinin ek karmaşıklığı bu veri seti için belirgin bir avantaj sağlamamıştır.

Destek Vektör Makinesi (SVM) algoritmaları incelendiğinde, Doğrusal SVM'in (%87,01) RBF çekirdekli SVM'den (%85,71) daha iyi performans gösterdiği görülmektedir. Bu bulgu, hasar sınıflarının özellik uzayında büyük ölçüde doğrusal olarak ayrılabilirliğini göstermektedir. K-En Yakın Komşu (KNN) algoritması %84,42 doğruluk ile dördüncü sırada yer almıştır. Naive Bayes algoritması %54,55 doğruluk ile en düşük performansı sergilemiştir.



Şekil 3.1. Model performans karşılaştırma grafiği



Şekil 3.2. F1-skoru bazında model sıralaması

3.2. Çapraz Doğrulama Sonuçları


Model performansının tutarlılığını ve güvenilirliğini değerlendirmek için 5-katlı çapraz doğrulama (5-Fold Cross-Validation) uygulanmıştır. Bu yöntemde veri seti 5 eşit parçaya bölünmekte, her iterasyonda bir parça test için ayrılırken kalan 4 parça eğitim için kullanılmaktadır. Çizelge 3.2'de tüm modellerin çapraz doğrulama sonuçları sunulmaktadır.

Çizelge 3.2. Çapraz doğrulama sonuçları (5-Fold CV)

Model	CV Ortalama	Std Sapma	Test Doğ.	Test-CV Farkı
RBF SVM	%90,5	$\pm\%3,8$	%85,71	-4,79%
Rastgele Orman	%89,6	$\pm\%3,4$	%93,51	+3,91%
KNN	%86,6	$\pm\%4,7$	%84,42	-2,18%
Doğrusal SVM	%86,0	$\pm\%2,2$	%87,01	+1,01%
Karar Ağacı	%85,4	$\pm\%5,1$	%94,81	+9,41%
Naive Bayes	%66,4	$\pm\%2,5$	%54,55	-11,85%

Çapraz doğrulama sonuçları incelendiğinde dikkat çekici bulgular ortaya çıkmaktadır. En yüksek CV skoru RBF çekirdekli SVM tarafından elde edilmiştir (%90,5). Bu sonuç, tek test setinde en iyi performansı gösteren Karar Ağacı'nın (%94,81) çapraz doğrulamada daha düşük ortalama (%85,4) ve daha yüksek standart sapma ($\pm\%5,1$) göstermesi nedeniyle önem taşımaktadır.

En kararlı model Doğrusal SVM olarak belirlenmiştir ($\pm\%2,2$ standart sapma). Test doğruluğu ile CV ortalaması arasındaki fark (genelleme açığı), modellerin aşırı öğrenme (overfitting) eğilimini göstermektedir. Karar Ağacı için bu fark +%9,41 olup en yüksek değerdir.



Şekil 3.3. Çapraz doğrulama sonuçları


3.3. Sınıf Bazlı Performans Analizi

En yüksek test performansını gösteren Karar Ağacı modelinin sınıf bazlı performansı Çizelge 3.3'te detaylandırılmıştır. Bu analiz, modelin hangi hasar seviyelerini ne kadar başarılı ayırt edebildiğini ortaya koymaktadır.

Çizelge 3.3. Karar Ağacı sınıf bazlı performans metrikleri

Sınıf	Kesinlik	Duyarlılık	F1-Skor	Destek
Hasarsız (0 mm)	%100,0	%100,0	%100,0	20
Hafif Hasar (3,88 mm)	%93,8	%88,2	%90,9	17
Orta Hasar (7,80 mm)	%90,0	%90,0	%90,0	20
Kritik Hasar (10,00 mm)	%95,2	%100,0	%97,6	20

Hasarsız sınıf (Sınıf 0) için mükemmel performans elde edilmiştir. 20 test örneğinin tamamı doğru sınıflandırılmış olup hem kesinlik hem de duyarlılık değerleri %100'dür. Kritik hasar sınıfı (Sınıf 3) için de çok yüksek performans gözlenmiştir. Duyarlılık değeri %100 olup bu, tüm kritik hasar durumlarının tespit edildiği anlamına gelmektedir.




Şekil 3.4. Sınıf bazlı performans grafiği

3.4. Karışıklık Matrisi Analizi

Karışıklık matrisi (confusion matrix), modelin tahmin dağılımını detaylı olarak sunmaktadır. Matrisin köşegenindeki değerler doğru tahminleri, köşegen dışındaki değerler ise hataları temsil etmektedir.

Çizelge 3.4. Karar Ağacı karışıklık matrisi


Gerçek \ Tahmin	Hasarsız	3,88 mm	7,80 mm	Kritik
Hasarsız	20	0	0	0
3,88 mm	0	15	2	0
7,80 mm	0	1	18	1
Kritik	0	0	0	20



Şekil 3.5. Tüm modellerin karışıklık matrisleri karşılaştırması

Şekil 3.5'te altı modelin karışıklık matrisleri yan yana sunulmaktadır. Karar Ağacı ve Rastgele Orman modellerinde köşegen değerlerin belirgin şekilde baskın olduğu görülmektedir. Naive Bayes modelinde ise tahminlerin sınıflar arasında dağınık olduğu gözlemlenmektedir.


3.4.1. Karar Ağacı karışıklık matrisi



Şekil 3.6. Karar Ağacı karışıklık matrisi (Doğruluk: %94,81)

Sonuçlar incelendiğinde, hasarsız (Undamaged) ve kritik hasar (2,20mm Critical) sınıflarının %100 doğrulukla tespit edildiği görülmektedir. Modelin toplam 4 hatası bulunmakta olup bu hataların tamamı komşu hasar seviyeleri arasında gerçekleşmiştir: 3,88mm kesimli 2 örnek 3,92mm olarak, 3,92mm kesimli 1 örnek 3,88mm ve 1 örnek kritik hasar olarak yanlış sınıflandırılmıştır. Bu durum, yakın hasar seviyelerinin benzer titreşim karakteristikleri sergilemesinden kaynaklanmaktadır. Modelin uç sınıfları (hasarsız ve kritik) mükemmel ayırt edebilmesi, sistemin güvenlik açısından kritik durumları güvenilir şekilde tespit edebildiğini göstermektedir.


3.4.2. Rastgele Orman karışıklık matrisi



Şekil 3.7. Rastgele Orman karışıklık matrisi (Doğruluk: %93,51)

Rastgele Orman modeli toplam 5 hatalı sınıflandırma yapmıştır. Hafif hasar (3,88mm) ve kritik hasar (2,20mm) sınıfları %100 doğrulukla tespit edilmiştir. Hasarsız sınıftan 1 örnek hafif hasar olarak yanlış sınıflandırılmıştır. En fazla karışıklık orta hasar (3,92mm) sınıfında yaşanmış olup 20 örneğin 4'ü hatalı tahmin edilmiştir: 3 örnek hafif hasar, 1 örnek kritik hasar olarak sınıflandırılmıştır. Bu durum, orta hasar seviyesinin hem hafif hem de kritik hasarla benzer titreşim karakteristikleri paylaşmasından kaynaklanmaktadır. Model, uç seviyeleri (hasarsız ve kritik) yüksek güvenilirlikle ayırt edebilmekte, ara seviyelerde ise görece daha fazla belirsizlik göstermektedir.


3.4.3. Doğrusal SVM karışıklık matrisi



Şekil 3.8. Doğrusal SVM karışıklık matrisi (Doğruluk: %87,01)

Doğrusal SVM modeli toplam 10 hatalı sınıflandırma yapmıştır. Hasarsız sınıf %100 doğrulukla tespit edilmiş olup bu sınıfta herhangi bir hata bulunmamaktadır. Hafif hasar (3,88mm) sınıfında 17 örneğin 16'sı doğru sınıflandırılmış, 1 örnek orta hasar olarak tahmin edilmiştir. Orta hasar (3,92mm) sınıfı en fazla karışıklığın yaşandığı sınıf olup 20 örneğin yalnızca 15'i doğru tespit edilmiştir; 3 örnek hafif hasar, 2 örnek kritik hasar olarak yanlış sınıflandırılmıştır. Kritik hasar sınıfında ise 20 örneğin 4'ü orta hasar olarak tahmin edilmiş, %80 doğruluk elde edilmiştir. Model, doğrusal karar sınırlarının ara hasar seviyelerini ayırt etmede yetersiz kaldığını göstermektedir.


3.4.4. RBF çekirdekli SVM karışıklık matrisi



Şekil 3.9. RBF çekirdekli SVM karışıklık matrisi (Doğruluk: %85,71)

RBF çekirdekli SVM modeli toplam 11 hatalı sınıflandırma yapmıştır. Hasarsız sınıfta 20 örneğin 19'u doğru tespit edilmiş, 1 örnek kritik hasar olarak yanlış sınıflandırılmıştır; bu, hasarsız bir pervanenin kritik hasarlı olarak algılanması anlamına gelen dikkat çekici bir hatadır. Hafif hasar (3,88mm) sınıfında 17 örneğin 16'sı doğru tahmin edilmiş, 1 örnek orta hasar olarak sınıflandırılmıştır. Orta hasar (3,92mm) sınıfı en problemli sınıf olup 20 örneğin yalnızca 15'i doğru tespit edilmiştir; 1 örnek hafif hasar, 4 örnek kritik hasar olarak yanlış sınıflandırılmıştır. Kritik hasar sınıfında ise 20 örneğin 4'ü orta hasar olarak tahmin edilmiştir. Doğrusal olmayan karar sınırlarının bu veri seti için ek bir avantaj sağlamadığı görülmektedir.

3.4.5. K-En Yakın Komşu karışıklık matrisi



Şekil 3.10. KNN karışıklık matrisi (Doğruluk: %84,42)

KNN modeli toplam 12 hatalı sınıflandırma yapmıştır. Hasarsız sınıfta 20 örneğin 19'u doğru tespit edilmiş, 1 örnek orta hasar olarak yanlış sınıflandırılmıştır. Hafif hasar (3,88mm) sınıfında 17 örneğin 16'sı doğru tahmin edilmiş, 1 örnek kritik hasar olarak sınıflandırılmıştır; bu, hafif hasarın en ağır seviye olarak algılanması anlamına gelen önemli bir hatadır. Orta hasar (3,92mm) sınıfı en düşük performansın görüldüğü sınıf olup 20 örneğin yalnızca 12'si (%60) doğru tespit edilmiştir; 4 örnek hafif hasar, 4 örnek kritik hasar olarak yanlış sınıflandırılmıştır. Kritik hasar sınıfında 20 örneğin 18'i doğru tahmin edilmiş, 2 örnek orta hasar olarak sınıflandırılmıştır.

3.4.6. Naive Bayes karışıklık matrisi




Şekil 3.11. Naive Bayes karışıklık matrisi (Doğruluk: %54,55)

Naive Bayes modeli toplam 35 hatalı sınıflandırma ile en düşük performansı sergilemiştir. Hasarsız sınıfta 20 örneğin yalnızca 13'ü (%65) doğru tespit edilmiş; 1 örnek hafif hasar, 2 örnek orta hasar ve 4 örnek kritik hasar olarak yanlış sınıflandırılmıştır. Hafif hasar (3,88mm) sınıfında 17 örneğin 14'ü doğru tahmin edilmiş olup bu sınıf modelin en başarılı olduğu kategoridir. Orta hasar (3,92mm) sınıfında 20 örneğin 11'i (%55) doğru tespit edilmiş, 3 örnek hafif hasar ve 6 örnek kritik hasar olarak sınıflandırılmıştır. Kritik hasar sınıfı en problemlili kategori olup 20 örneğin yalnızca 4'ü (%20) doğru tespit edilmiş, 15 örnek orta hasar olarak yanlış sınıflandırılmıştır. Özellikler arası bağımsızlık varsayımının bu veri seti için geçerli olmadığı ve modelin pratik kullanım için uygun olmadığı açıkça görülmektedir.


3.5. ROC Eğrisi Analizi

ROC (Receiver Operating Characteristic) eğrisi, sınıflandırıcının farklı eşik değerlerinde doğru pozitif oranı (TPR) ile yanlış pozitif oranı (FPR) arasındaki ilişkiyi göstermektedir. Eğri altında kalan alan (AUC), modelin sınıfları ayırt etme yeteneğinin genel bir ölçüsüdür.



Şekil 3.12. Tüm modellerin ROC eğrileri karşılaştırması

3.5.1. Karar Ağacı ROC eğrisi




Şekil 3.13. Karar Ağacı ROC eğrisi

Karar Ağacı modeli 0,964 ortalama AUC değeri ile yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AUC değeri ile mükemmel ayırt edilebilirlik göstermekte olup eğri sol üst köşeye tam olarak ulaşmaktadır. Kritik hasar sınıfı da 0,991 AUC ile neredeyse mükemmel performans sergilemektedir. Hafif hasar (3,88mm) ve orta hasar (3,92mm) sınıfları sırasıyla 0,933 ve 0,932 AUC değerleri ile

birbirine çok yakın performans göstermektedir; bu durum, ara hasar seviyelerinin benzer titreşim karakteristikleri nedeniyle ayırt edilmesinin görece daha zor olduğunu göstermektedir. Tüm sınıfların eğrileri sol üst köşeye yakın konumlanmakta olup model, farklı karar eşiklerinde de tutarlı bir performans sergilemektedir.


3.5.2. Rastgele Orman ROC eğrisi



Şekil 3.14. Rastgele Orman ROC eğrisi

Rastgele Orman modeli 0,987 ortalama AUC değeri ile çok yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AUC değeri ile mükemmel ayırt edilebilirlik göstermektedir. Hafif hasar (3,88mm) sınıfı 0,999 AUC ile neredeyse mükemmel performans sergilemektedir. Kritik hasar sınıfı 0,988 AUC değeri ile yüksek başarı göstermektedir. Orta hasar (3,92mm) sınıfı 0,961 AUC ile diğer sınıflara göre görece daha düşük performans sergilemiş olup eğrinin basamaklı yapısı bu sınıftaki sınıflandırma belirsizliğini yansıtmaktadır. Tüm sınıfların eğrileri sol üst köşeye yakın konumlanmakta olup model, farklı karar eşiklerinde tutarlı ve güvenilir bir performans sergilemektedir.


3.5.3. Doğrusal SVM ROC eğrisi



Şekil 3.15. Doğrusal SVM ROC eğrisi

Doğrusal SVM modeli 0,949 ortalama AUC değeri ile iyi bir sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AUC değeri ile mükemmel ayırt edilebilirlik göstermektedir. Kritik hasar sınıfı 0,982 AUC ile yüksek performans sergilemektedir. Hafif hasar (3,88mm) sınıfı 0,972 AUC değeri ile başarılı bir şekilde ayırt edilmektedir. Orta hasar (3,92mm) sınıfı 0,844 AUC ile en düşük performansı göstermekte olup eğrinin basamaklı ve daha yatık yapısı bu sınıftaki sınıflandırma zorluğunu açıkça ortaya koymaktadır. Doğrusal karar sınırlarının uç hasar seviyelerini başarıyla ayırt edebildiği, ancak ara seviyelerde yetersiz kaldığı görülmektedir.


3.5.4. RBF çekirdekli SVM ROC eğrisi



Şekil 3.16. RBF çekirdekli SVM ROC eğrisi

RBF çekirdekli SVM modeli 0,979 ortalama AUC değeri ile yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 0,999 AUC değeri ile neredeyse mükemmel ayırt edilebilirlik göstermektedir. Hafif hasar (3,88mm) sınıfı 0,996 AUC ile çok yüksek performans sergilemektedir. Kritik hasar sınıfı 0,979 AUC değeri ile başarılı bir şekilde ayırt edilmektedir. Orta hasar (3,92mm) sınıfı 0,941 AUC ile diğer sınıflara göre daha düşük performans göstermekte olup eğrinin basamaklı yapısı bu sınıftaki sınıflandırma belirsizliğini yansıtmaktadır. Doğrusal olmayan karar sınırlarının tüm hasar seviyelerinde tutarlı bir ayırt edicilik sağladığı görülmektedir.


3.5.5. K-En Yakın Komşu ROC eğrisi



Şekil 3.17. KNN ROC eğrisi

KNN modeli 0,960 ortalama AUC değeri ile iyi bir sınıflandırma performansı sergilemektedir. Hasarsız sınıf 0,998 AUC değeri ile neredeyse mükemmel ayırt edilebilirlik göstermektedir. Hafif hasar (3,88mm) sınıfı 0,987 AUC ile yüksek performans sergilemektedir. Kritik hasar sınıfı 0,965 AUC değeri ile başarılı bir şekilde ayırt edilmektedir. Orta hasar (3,92mm) sınıfı 0,889 AUC ile en düşük performansı göstermekte olup eğrinin belirgin basamaklı yapısı ve daha yatık seyri bu sınıftaki sınıflandırma zorluğunu ortaya koymaktadır. Örnek tabanlı öğrenme yaklaşımının uç hasar seviyelerinde güçlü, ara seviyelerde ise zayıf performans sergilediği görülmektedir.

3.5.6. Naive Bayes ROC eğrisi




Şekil 3.18. Naive Bayes ROC eğrisi

Naive Bayes modeli 0,759 ortalama AUC değeri ile düşük sınıflandırma performansı sergilemektedir. Hafif hasar (3,88mm) sınıfı 0,880 AUC ile modelin en başarılı olduğu kategoridir. Hasarsız sınıf 0,853 AUC değeri ile kabul edilebilir bir ayırt edicilik göstermektedir. Kritik hasar sınıfı 0,685 AUC ile zayıf performans sergilemekte olup eğrinin diagonal çizgiye yakın seyretmesi bu sınıftaki sınıflandırma güçlüğüne ortaya koymaktadır. Orta hasar (3,92mm) sınıfı 0,618 AUC ile en düşük performansı göstermektedir. Tüm sınıfların eğrilerinin belirgin basamaklı ve düzensiz yapısı, modelin farklı karar eşiklerinde tutarsız performans sergilediğini göstermektedir. Naive Bayes özelliklerin birbirinden bağımsız olduğunu varsayar; ancak bu veri setinde titreşim öznelikleri aynı mekanik kaynaktan türediği için yüksek korelasyon göstermekte ve bu durum modelin performansını düşürmektedir.


3.6. Precision-Recall Analizi

Precision-Recall (PR) eğrisi, farklı karar eşiklerinde kesinlik ve duyarlılık değerlerinin değişimini göstermektedir. PR eğrisi özellikle dengesiz sınıf dağılımlarında ROC eğrisine göre daha bilgilendirici olabilmektedir.



Şekil 3.19. Tüm modellerin Precision-Recall eğrileri karşılaştırması

3.6.1. Karar Ağacı Precision-Recall eğrisi




Şekil 3.20. Karar Ağacı Precision-Recall eğrisi

Karar Ağacı modeli 0,910 ortalama AP (Average Precision) değeri ile yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AP değeri ile mükemmel kesinlik-duyarlılık dengesi göstermekte olup eğri tüm recall değerlerinde maksimum precision seviyesini korumaktadır. Kritik hasar sınıfı 0,952 AP ile yüksek performans sergilemektedir. Hafif hasar (3,88mm) sınıfı 0,853 AP değeri ile başarılı bir performans

göstermektedir. Orta hasar (3,92mm) sınıfı 0,836 AP ile en düşük performansı sergilemekte olup eğrinin yüksek recall değerlerinde keskin düşüş göstermesi, bu sınıfta tüm örnekleri yakalamaya çalışıldığında kesinliğin azaldığını ortaya koymaktadır. Model genel olarak yüksek recall değerlerinde bile precision seviyesini koruyabilmektedir.


3.6.2. Rastgele Orman Precision-Recall eğrisi



Şekil 3.21. Rastgele Orman Precision-Recall eğrisi

Rastgele Orman modeli 0,968 ortalama AP değeri ile çok yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AP değeri ile mükemmel kesinlik-duyarlılık dengesi göstermektedir. Hafif hasar (3,88mm) sınıfı 0,997 AP ile neredeyse mükemmel performans sergilemektedir. Kritik hasar sınıfı 0,942 AP değeri ile yüksek başarı göstermekte olup eğrideki basamaklı yapı orta recall değerlerinde kısa süreli precision düşüşünü yansıtmaktadır. Orta hasar (3,92mm) sınıfı 0,934 AP ile diğer sınıflara göre görece daha düşük performans sergilemekte olup yüksek recall değerlerinde precision'ın belirgin şekilde düştüğü görülmektedir. Model genel olarak tüm sınıflarda yüksek kesinlik-duyarlılık dengesi sağlamaktadır.


3.6.3. Doğrusal SVM Precision-Recall eğrisi



Şekil 3.22. Doğrusal SVM Precision-Recall eğrisi

Doğrusal SVM modeli 0,890 ortalama AP değeri ile iyi bir sınıflandırma performansı sergilemektedir. Hasarsız sınıf 1,000 AP değeri ile mükemmel kesinlik-duyarlılık dengesi göstermekte olup eğri tüm recall değerlerinde maksimum precision seviyesini korumaktadır. Kritik hasar sınıfı 0,937 AP ile yüksek performans sergilemektedir. Hafif hasar (3,88mm) sınıfı 0,842 AP değeri ile orta düzey başarı göstermekte olup eğrinin basamaklı yapısı farklı karar eşiklerinde precision dalgalanmalarını yansıtmaktadır. Orta hasar (3,92mm) sınıfı 0,780 AP ile en düşük performansı sergilemekte olup eğrinin recall arttıkça belirgin şekilde düşmesi, bu sınıfta yüksek duyarlılık hedeflendiğinde kesinliğin ciddi şekilde azaldığını ortaya koymaktadır.


3.6.4. RBF çekirdekli SVM Precision-Recall eğrisi



Şekil 3.23. RBF çekirdekli SVM Precision-Recall eğrisi

RBF çekirdekli SVM modeli 0,954 ortalama AP değeri ile yüksek sınıflandırma performansı sergilemektedir. Hasarsız sınıf 0,998 AP değeri ile neredeyse mükemmel kesinlik-duyarlılık dengesi göstermektedir. Hafif hasar (3,88mm) sınıfı 0,989 AP ile çok yüksek performans sergilemektedir. Kritik hasar sınıfı 0,946 AP değeri ile başarılı bir performans göstermekte olup eğrideki basamaklı yapı orta recall değerlerinde kısa süreli precision dalgalanmalarını yansıtmaktadır. Orta hasar (3,92mm) sınıfı 0,884 AP ile en düşük performansı sergilemekte olup eğrinin recall arttıkça belirgin şekilde düşmesi ve dalgalı seyri, bu sınıfta kesinlik-duyarlılık dengesinin sağlanmasının zorluğunu ortaya koymaktadır.


3.6.5. K-En Yakın Komşu Precision-Recall eğrisi



Şekil 3.24. KNN Precision-Recall eğrisi

KNN modeli 0,936 ortalama AP değeri ile iyi bir sınıflandırma performansı sergilemektedir. Hasarsız sınıf 0,995 AP değeri ile neredeyse mükemmel kesinlik-duyarlılık dengesi göstermektedir. Hafif hasar (3,88mm) sınıfı 0,975 AP ile yüksek performans sergilemektedir. Kritik hasar sınıfı 0,954 AP değeri ile başarılı bir performans göstermekte olup eğrideki basamaklı yapı orta recall değerlerinde precision dalgalanmalarını yansıtmaktadır. Orta hasar (3,92mm) sınıfı 0,821 AP ile en düşük performansı sergilemekte olup eğrinin recall arttıkça keskin ve sürekli düşüş göstermesi, bu sınıfta tüm örnekleri yakalamaya çalışıldığında kesinliğin ciddi şekilde azaldığını ortaya koymaktadır.

3.6.6. Naive Bayes Precision-Recall eğrisi



Şekil 3.25. Naive Bayes Precision-Recall eğrisi


Naive Bayes modeli 0,541 ortalama AP değeri ile düşük sınıflandırma performansı sergilemektedir. Hasarsız sınıf 0,778 AP değeri ile modelin en başarılı olduğu kategori olmakla birlikte, eğrinin recall arttıkça sürekli düşüş göstermesi kesinlik-duyarlılık dengesinin sağlanamadığını ortaya koymaktadır. Hafif hasar (3,88mm) sınıfı 0,696 AP ile orta düzey performans sergilemektedir. Kritik hasar sınıfı 0,358 AP değeri ile çok düşük performans göstermekte olup eğrinin dalgalı ve düşük seyri bu sınıftaki ciddi sınıflandırma zorluğunu yansıtmaktadır. Orta hasar (3,92mm) sınıfı 0,333 AP ile en düşük performansı sergilemekte olup eğrinin düşük recall değerlerinde bile hızla precision kaybetmesi, modelin bu sınıfı ayırt etmede yetersiz kaldığını göstermektedir.

3.7. Öğrenme Eğrileri ve Overfitting Analizi

Öğrenme eğrileri, eğitim seti boyutu arttıkça model performansının nasıl değiştiğini göstermektedir. Bu eğriler, modelin aşırı öğrenme (overfitting) veya yetersiz öğrenme (underfitting) durumlarını tespit etmek için kullanılmaktadır.


Çizelge 3.5. Eğitim-test doğruluk farkları ve overfitting analizi

Model	Eğitim Doğ.	Test Doğ.	Fark	Durum
Karar Ağacı	%100,00	%94,81	%5,19	Hafif overfitting
Rastgele Orman	%100,00	%93,51	%6,49	Hafif overfitting
Doğrusal SVM	%100,00	%87,01	%12,99	Overfitting
RBF SVM	%100,00	%85,71	%14,29	Overfitting
KNN	%100,00	%84,42	%15,58	Overfitting
Naive Bayes	%75,90	%54,55	%21,35	Underfitting



Şekil 3.26. Tüm modellerin öğrenme eğrileri karşılaştırması


3.7.1. Karar Ağacı öğrenme eğrisi



Şekil 3.27. Karar Ağacı öğrenme eğrisi

Karar Ağacı modelinin öğrenme eğrisi, eğitim süreci boyunca model performansının nasıl değiştiğini göstermektedir. Eğitim skoru (mavi çizgi) tüm veri boyutlarında 1,000 değerinde sabit kalmakta olup model, eğitim verisini mükemmel şekilde ezberlemektedir. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,50 seviyesinden başlayarak, örnek sayısı arttıkça yükselmekte ve 250 örnekte 0,854 değerine ulaşmaktadır. Eğitim ve CV skorları arasındaki belirgin fark (yaklaşık %15) modelin aşırı öğrenme (overfitting) eğiliminde olduğunu göstermektedir. Turuncu gölgeli alan CV skorunun standart sapmasını temsil etmekte olup bu alanın genişliği modelin farklı veri bölünmelerinde değişken performans sergilediğine işaret etmektedir. CV skorunun eğitim örneği arttıkça yükselmeye devam etmesi, daha fazla veri ile performansın artabileceğini düşündürmektedir.


3.7.2. Rastgele Orman öğrenme eğrisi



Şekil 3.28. Rastgele Orman öğrenme eğrisi

Rastgele Orman modelinin öğrenme eğrisi, eğitim süreci boyunca model performansının nasıl değiştiğini göstermektedir. Eğitim skoru (mavi çizgi) tüm veri boyutlarında 1,000 değerinde sabit kalmakta olup model, eğitim verisini mükemmel şekilde ezberlemektedir. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,71 seviyesinden başlayarak, örnek sayısı arttıkça yükselmekte ve 250 örnekte 0,905 değerine ulaşmaktadır. Eğitim ve CV skorları arasındaki fark (yaklaşık %10) modelin aşırı öğrenme eğiliminde olduğunu göstermekle birlikte, bu fark görece kabul edilebilir seviyededir. Turuncu gölgeli alan CV skorunun standart sapmasını temsil etmekte olup örnek sayısı arttıkça bu alanın daralması modelin daha tutarlı hale geldiğine işaret etmektedir.


3.7.3. Doğrusal SVM öğrenme eğrisi



Şekil 3.29. Doğrusal SVM öğrenme eğrisi

Doğrusal SVM modelinin öğrenme eğrisi, eğitim süreci boyunca model performansının nasıl değiştiğini göstermektedir. Eğitim skoru (mavi çizgi) tüm veri boyutlarında 1,000 değerinde sabit kalmakta olup model, eğitim verisini mükemmel şekilde sınıflandırmaktadır. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,64 seviyesinden başlayarak, örnek sayısı arttıkça yükselmekte ve 250 örnekte 0,853 değerine ulaşmaktadır. Eğitim ve CV skorları arasındaki belirgin fark (yaklaşık %15) modelin aşırı öğrenme eğiliminde olduğunu göstermektedir. Turuncu gölgeli alan CV skorunun standart sapmasını temsil etmekte olup bu alanın genişliği modelin farklı veri bölünmelerinde değişken performans sergilediğine işaret etmektedir. CV skorunun 100 örnek civarında platoya ulaşması ve sonrasında yatay seyretmesi, doğrusal karar sınırlarının bu veri seti için kapasitesinin sınırına ulaştığını düşündürmektedir.


3.7.4. RBF çekirdekli SVM öğrenme eğrisi



Şekil 3.30. RBF çekirdekli SVM öğrenme eğrisi

RBF çekirdekli SVM modelinin öğrenme eğrisi, eğitim süreci boyunca model performansının nasıl değiştiğini göstermektedir. Eğitim skoru (mavi çizgi) tüm veri boyutlarında 1,000 değerinde sabit kalmakta olup model, eğitim verisini mükemmel şekilde sınıflandırmaktadır. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,55 seviyesinden başlayarak, örnek sayısı arttıkça sürekli yükselmekte ve 250 örnekte 0,905 değerine ulaşmaktadır. Eğitim ve CV skorları arasındaki fark (yaklaşık %10) modelin aşırı öğrenme eğiliminde olduğunu göstermekle birlikte, bu fark kabul edilebilir seviyededir. Turuncu gölgeli alan CV skorunun standart sapmasını temsil etmekte olup örnek sayısı arttıkça bu alanın kısmen daraldığı görülmektedir.


3.7.5. K-En Yakın Komşu öğrenme eğrisi



Şekil 3.31. KNN öğrenme eğrisi

KNN modelinin öğrenme eğrisi, eğitim süreci boyunca model performansının nasıl değiştiğini göstermektedir. Eğitim skoru (mavi çizgi) tüm veri boyutlarında 1,000 değerinde sabit kalmakta olup model, eğitim verisini mükemmel şekilde sınıflandırmaktadır. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,58 seviyesinden başlayarak, örnek sayısı arttıkça istikrarlı bir şekilde yükselmekte ve 250 örnekte 0,866 değerine ulaşmaktadır. Eğitim ve CV skorları arasındaki belirgin fark (yaklaşık %13) modelin aşırı öğrenme eğiliminde olduğunu göstermektedir. Turuncu gölgeli alan CV skorunun standart sapmasını temsil etmekte olup bu alanın tüm veri boyutlarında geniş kalması modelin farklı veri bölünmelerinde değişken performans sergilediğine işaret etmektedir.

3.7.6. Naive Bayes öğrenme eğrisi



Şekil 3.32. Naive Bayes öğrenme eğrisi

Naive Bayes modelinin öğrenme eğrisi, diğer modellerden farklı bir örüntü sergilemektedir. Eğitim skoru (mavi çizgi) 1,000 değerinde sabit kalmak yerine, düşük örnek sayılarında yaklaşık 0,97 seviyesinden başlayarak örnek sayısı arttıkça düşmekte ve 250 örnekte 0,769 değerine gerilemektedir. Bu durum, modelin eğitim verisini bile tam olarak sınıflandıramadığını göstermektedir. CV skoru (turuncu çizgi) düşük örnek sayılarında yaklaşık 0,39 seviyesinden başlayarak yükselmekte ancak 100 örnek civarında 0,70 seviyesinde platoya ulaşmakta ve 250 örnekte 0,664 değerinde kalmaktadır. Eğitim ve CV skorlarının birbirine yaklaşması tipik olarak iyi bir işaret olmakla birlikte, burada her iki skorun da düşük seviyelerde kalması modelin yetersiz öğrenme (underfitting) durumunda olduğunu ortaya koymaktadır.


3.8. Özellik Önem Analizi

Ağaç tabanlı algoritmalar, özellik önemlerini (feature importance) hesaplayabilmektedir. Bu analiz, pervane hasarının sensör verilerinde nasıl yansıdığını anlamak için kritik bilgiler sağlamaktadır.


Çizelge 3.6. En önemli 10 özellik (Rastgele Orman)

Özellik	Önem Skoru	Kategori
VIBE[0].VibeX_p90	0,4221	Titreşim
VIBE[0].VibeX_max	0,1236	Titreşim
VIBE[0].VibeX_median	0,0925	Titreşim
VIBE[0].VibeX_rms	0,0907	Titreşim
VIBE[0].VibeX_mean	0,0224	Titreşim
IMU[2].AccZ_std	0,0187	İvme
RCOU.C1_mean	0,0156	Motor
IMU[2].GyrZ_std	0,0134	Jiroskop
motor_balance_std	0,0098	Türetilmiş
ATT.Roll_Error_std	0,0076	Tutum

En önemli özellik olarak VIBE[0].VibeX_p90 (X eksen titreşiminin 90. yüzdeliği) tespit edilmiştir. Bu tek özellik, modelin karar verme sürecinin %42,21'ini açıklamaktadır. İlk 5 özelliğin tamamı VibeX parametresinden türetilmiştir ve toplam önem skorunun %75'inden fazlasını oluşturmaktadır.



Şekil 3.33. Rastgele Orman özellik önem grafiği




Şekil 3.34. Karar Ağacı özellik önem grafiği

3.9. Fiziksel Sensör Verileri Analizi

Bu bölümde, pervane hasarının fiziksel sensör verileri üzerindeki etkisi analiz edilmektedir. Titreşim, tutum hataları ve motor çıkışları, hasar seviyesine göre sistematik değişimler göstermektedir.


3.9.1. Titreşim analizi



Şekil 3.35. Hasar seviyelerine göre titreşim analizi

Şekil 3.35'te farklı hasar seviyelerindeki titreşim paternleri gösterilmektedir. Hasarsız durumda düşük ve simetrik titreşim gözlenirken, hasar arttıkça titreşim genliği ve asimetrisi belirgin şekilde artmaktadır.

3.9.2. Tutum hataları analizi



Şekil 3.36. Hasar seviyelerine göre tutum (attitude) hataları

Şekil 3.36'da roll, pitch ve yaw açılarındaki hataların hasar seviyesine göre dağılımı gösterilmektedir. Hasarsız durumda minimal hata gözlenirken, hasarlı pervanelerde tutum kontrolü zorlaşmakta ve osilas-yonlar artmaktadır.

3.9.3. Motor çıkışları analizi



Şekil 3.37. Hasar seviyelerine göre motor çıkışları

Şekil 3.37'de dört motorun çıkış değerlerinin hasar seviyesine göre değişimi gösterilmektedir. Hasarsız durumda tüm motorlar dengeli çıkış gösterirken, hasarlı durumda Motor 1 daha yüksek çıkış üretmekte ve motor dengesizliği artmaktadır.

3.10. Hesaplama Verimliliği Analizi

Gerçek zamanlı hasar tespit sistemlerinin pratik uygulanabilirliği, algoritmaların hesaplama verimliliğine doğrudan bağlıdır.

Çizelge 3.7. Hesaplama verimliliği metrikleri

Metrik	Değer
Eğitim Süresi (Grid Search dahil)	~43,3 saniye
Tahmin Süresi (örnek başına)	~0,12 ms
Tahmin Kapasitesi	~8.333 örnek/saniye
Model Dosya Boyutu	~8,4 MB
Çalışma Zamanı Bellek Kullanımı	~125 MB
Gerçek Zamanlı Uygunluk	Uygun

Örnek başına 0,12 ms tahmin süresi elde edilmiştir. Veri toplama örnekleme frekansı 108 Hz olup tahmin süresi örnekleme periyodunun yaklaşık %1,3'üne karşılık gelmektedir. Model dosya boyutu (8,4 MB) ve bellek kullanımı (125 MB), modern uçuş kontrolcülerinin kapasitelerinin altındadır.

3.11. Bulgular Özeti

Bu bölümde sunulan deneysel sonuçlar, geliştirilen pervane hasar tespit sisteminin etkinliğini doğrulamaktadır. Karar Ağacı algoritması %94,81 test doğruluğu ile en yüksek performansı göstermiştir. Ancak çapraz doğrulama sonuçları değerlendirildiğinde RBF çekirdekli SVM'in %90,5 ortalama ile en yüksek CV skoruna sahip olduğu görülmektedir.

Hasarsız ve kritik hasar sınıfları %100'e yakın doğrulukla ayırt edilebilmektedir. Özellik önemi analizi, titreşim verilerinin (özellikle VibeX_p90) pervane hasarı tespitinde en güçlü prediktörler olduğunu ortaya koymuştur. Sistem gerçek zamanlı çalışmaya uygundur (0,12 ms/tahmin) ve model edge deployment için yeterince kompakttır.

4. SONUÇ

Bu çalışmada, quadrotor İHA platformlarında pervane hasarının gerçek zamanlı tespiti için IMU tabanlı bir makine öğrenmesi yaklaşımı geliştirilmiştir. Sistem, mevcut uçuş kontrolcüsü sensörlerinden elde edilen titreşim verilerini kullanarak dört farklı hasar seviyesini sınıflandırmayı amaçlamıştır. Deneyler, kontrollü laboratuvar ortamı yerine gerçek açık alan koşullarında ve otonom uçuş modunda gerçekleştirilmiştir.

Altı farklı makine öğrenmesi algoritmasının karşılaştırmalı değerlendirmesi sonucunda, ağaç tabanlı algoritmaların bu problem için daha uygun olduğu görülmüştür. Karar Ağacı algoritması test setinde en yüksek doğruluğu elde etmiş, Rastgele Orman ise bunu yakından takip etmiştir. Her iki algoritmanın da hasarsız ve kritik hasar sınıflarını yüksek güvenilirlikle ayırt edebildiği gözlemlenmiştir. Bu sonuç, titreşim verilerindeki hasar kaynaklı değişimlerin belirli eşik değerleri üzerinden ayrıştırılabilir nitelikte olduğuna işaret etmektedir.

Çapraz doğrulama sonuçları, tek test setindeki performans sıralamasından farklı bir tablo ortaya koymuştur. RBF çekirdekli SVM en yüksek ortalama çapraz doğrulama skorunu elde ederken, Doğrusal SVM en düşük standart sapmaya sahip olmuştur. Bu durum, model seçiminde tek bir test setine dayalı değerlendirmenin yanıltıcı olabileceğini göstermektedir. Pratik uygulamalarda, yüksek doğruluk kadar performans tutarlılığının da göz önünde bulundurulması gerekmektedir.

Özellik önemi analizi, X eksen titreşim verilerinin hasar tespitinde baskın bir rol oynadığını ortaya koymuştur. En önemli beş özelliğin tamamı VibeX parametresinden türetilmiş olup toplam karar verme sürecinin büyük bölümünü açıklamaktadır. Bu bulgu, pervane hasarının öncelikli olarak belirli bir titreşim ekseninde kendini gösterdiğini ve bu eksenin İHA'nın fiziksel konfigürasyonu ile ilişkili olduğunu göstermektedir. Hasarlı pervanenin konumu (ön sağ motor) ile X eksen titreşiminin baskınlığı arasındaki bu ilişki, farklı motor konumlarındaki hasarların farklı titreşim imzaları üretebileceğine işaret etmektedir.

Naive Bayes algoritmasının düşük performansı, özellikler arası bağımsızlık varsayımının bu veri seti için geçerli olmadığını göstermektedir. Titreşim, motor çıkışı ve tutum hataları arasındaki korelasyonlar, hasarın sistemde yarattığı zincirleme etkilerin bir

yansımasıdır. Bu korelasyonları yakalayabilen algoritmalar (ağaç tabanlı ve SVM) daha yüksek performans sergilemiştir.

Literatürdeki benzer çalışmalarla karşılaştırıldığında, bu çalışmanın elde ettiği doğruluk değerleri rekabetçi düzeydedir. Ancak doğrudan karşılaştırma yaparken bazı farklılıkların göz önünde bulundurulması gerekmektedir. Mevcut çalışmaların büyük çoğunluğu kontrollü laboratuvar koşullarında, sabit motor hızlarında veya yalnızca hover durumunda veri toplamıştır (Liu vd., 2024). Bu çalışmada ise dinamik uçuş senaryoları (dairesel ve sekiz rotası) kullanılmış ve veriler gerçek açık alan koşullarında toplanmıştır. Bu yaklaşım, modelin gerçek operasyonel koşullara genellenebilirliğini artırmakla birlikte, kontrollü ortam çalışmalarına kıyasla daha zorlu bir sınıflandırma problemi oluşturmaktadır.

Derin öğrenme tabanlı yaklaşımlar (CNN, LSTM) bazı çalışmalarda daha yüksek doğruluk değerleri raporlamıştır. Ancak bu çalışmada geleneksel makine öğrenmesi algoritmalarının tercih edilmesinin belirli gerekçeleri bulunmaktadır. Birincisi, hesaplama verimliliği açısından geleneksel algoritmalar gömülü sistemlerde daha kolay uygulanabilir durumdadır. İkincisi, model yorumlanabilirliği güvenlik kritik uygulamalarda önem taşımaktadır; bir karar ağacının neden belirli bir sınıflandırma yaptığı anlaşılabilirken, derin öğrenme modellerinin karar mekanizması çoğunlukla opak kalmaktadır. Üçüncüsü, derin öğrenme modelleri genellikle daha büyük veri setleri gerektirmekte olup bu çalışmadaki veri seti boyutu geleneksel algoritmalar için daha uygundur.

Geliştirilen sistemin pratik uygulanabilirliği birkaç açıdan değerlendirilebilir. Hesaplama verimliliği açısından, örnek başına tahmin süresi örnekleme periyodunun çok altında kalmaktadır. Bu durum, sistemin gerçek zamanlı çalışmaya uygun olduğunu göstermektedir. Model dosya boyutu ve bellek kullanımı, yaygın uçuş kontrolcülerinin (Pixhawk, Cube Orange vb.) kapasiteleri dahilindedir. Sistem, mevcut IMU sensörlerini kullandığından ek donanım maliyeti gerektirmemektedir.

Hasar tespit modülü, uçuş kontrolcüsünün ana döngüsüne paralel çalışarak sensör verilerini sürekli izleyebilir. Tespit edilen hasar seviyesine göre kademeli tepki stratejileri uygulanabilir: hafif hasarda uyarı mesajı, orta hasarda görev kısaltma önerisi, kritik hasarda otomatik güvenli iniş protokolü gibi.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Birincisi, hasar yalnızca tek bir pervaneye (Motor 1, ön sağ) ve tek bir kanat üzerine uygulanmıştır. Farklı motor konumlarındaki hasarların farklı titreşim imzaları üretip üretmeyeceği incelenmemiştir. İkincisi, deneyler tek bir İHA platformu üzerinde gerçekleştirilmiştir. Farklı boyut, ağırlık ve konfigürasyondaki platformlarda modelin performansı değerlendirilmemiştir. Üçüncüsü, çalışma yalnızca pervane hasarına odaklanmıştır. Motor arızaları, yapısal gevşemeler, sensör hataları gibi diğer arıza modları incelenmemiştir. Dördüncüsü, çevresel koşullar (rüzgar hızı, sıcaklık) nispeten sabit tutulmuştur. Ekstrem koşullarda modelin performansı test edilmemiştir.

Bu çalışmanın bulguları ışığında gelecek araştırmalar için çeşitli yönelimler önerilebilir. Veri seti genişletme açısından, daha fazla uçuş verisi toplanarak model güvenilirliği artırılabilir. Farklı motor konumlarında, farklı hasar paternlerinde ve çeşitli çevresel koşullarda veri toplama, modelin genellenebilirliğini güçlendirecektir. Çoklu arıza modu tespiti kapsamında, pervane hasarının yanı sıra motor yatağı aşınması, vida gevşemesi, kol çatlağı gibi diğer mekanik arızaların da tespit edilebileceği kapsamlı bir sistem geliştirilebilir.

Transfer öğrenme yaklaşımları, bir platformda eğitilen modelin farklı platformlara minimum uyarlama ile aktarılabilirliğini araştırabilir. Bu yaklaşım, her platform için ayrı veri toplama ve model eğitime ihtiyacını azaltabilir. Çevrimiçi öğrenme mekanizmaları, modelin uçuş sırasında sürekli güncellenmesini sağlayarak platform yaşlanması ve değişen koşullara adaptasyonu mümkün kılabilir. Hibrit yaklaşımlar, makine öğrenmesi modellerinin fizik tabanlı modellerle birleştirilmesini içerebilir; bu sayede veri odaklı ve model odaklı yaklaşımların güçlü yönleri bir araya getirilebilir. Hata toleranslı kontrol entegrasyonu kapsamında, hasar tespit sisteminin çıktılarının uçuş kontrolcüsüne aktararak otomatik kompanzasyon stratejilerinin uygulanması araştırılabilir.

Bu tez çalışması, quadrotor İHA platformlarında pervane hasarının IMU tabanlı titreşim verileri ve makine öğrenmesi algoritmaları kullanılarak tespit edilebileceğini göstermiştir. Gerçek uçuş koşullarında toplanan veriler üzerinde yapılan deneyler, ağaç tabanlı algoritmaların bu problem için yüksek performans sağladığını ortaya koymuştur.

Sistem, ek donanım gerektirmeden mevcut sensör altyapısını kullanması, gerçek zamanlı çalışmaya uygun hesaplama verimliliği sunması ve yorumlanabilir karar mekanizması sağlaması açısından pratik uygulanabilirlik potansiyeli taşımaktadır.

İHA teknolojisinin hızla yaygınlaşması ve kullanım alanlarının genişlemesiyle birlikte, operasyonel güvenlik konusu giderek daha kritik hale gelmektedir. Proaktif bakım yaklaşımları ve erken arıza tespit sistemleri, hem kaza riskini azaltmakta hem de operasyonel verimliliği artırmaktadır. Bu çalışma, düşük maliyetli ve uygulanabilir bir çözüm sunarak bu alandaki araştırmalara katkıda bulunmayı hedeflemiştir. Belirtilen sınırlılıkların giderilmesi ve önerilen gelecek çalışmaların gerçekleştirilmesiyle, İHA platformları için kapsamlı ve güvenilir bir sağlık izleme sisteminin geliştirilmesi mümkün olacaktır.

5. KAYNAKÇA

- Abdullah, M., Zulfiqar, A., Zeeshan Babar, M., Arman, J. H., Hafeez, G., Alsafran, A. S., ve Rawa, M. (2025). Hardware-in-the-Loop Experimental Validation of a Fault-Tolerant Control System for Quadcopter UAV Motor Faults. *Fractal and Fractional*, 9(11), 682. <https://doi.org/10.3390/fractalfract9110682>
- Al Ghozali, I. H., Pirman, A., ve Indra, I. (2023). Comparison of SVM and Naïve Bayes Algorithms with InNER Enriched to Predict Hate Speech. *El-Cezeri Fen ve Mühendislik Dergisi*, 10(3), 600-611. <https://doi.org/10.31202/ecjse.1325078>
- Aldossary, M., Alzamil, I., ve Almutairi, J. (2025). Enhanced Intrusion Detection in Drone Networks: A Cross-Layer Convolutional Attention Approach for Drone-to-Drone and Drone-to-Base Station Communications. *Drones*, 9(1), 46. <https://doi.org/10.3390/drones9010046>
- Ali, M., Mushtaq, M. F., Akram, U., Samee, N. A., Jamjoom, M. M., ve Ashraf, I. (2025). Detecting Vehicle Mechanical Defects Using an Ensemble Deep Learning Model with Mel Frequency Cepstral Coefficients from Acoustic Data. *Computer Modeling in Engineering & Sciences*, 145(2), 1863-1901. <https://doi.org/10.32604/cmcs.2025.070389>
- Alshari, H., Saleh, A. Y., ve Odabaş, A. (2021). Comparison of Gradient Boosting Decision Tree Algorithms for CPU Performance. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi (Erciyes University Journal of Institute of Science and Technology)*, 37(1), 157-168.
- Ateş, M. (2022). *Aykırı değerlerin tespit yöntemleri* [Yüksek Lisans Tezi]. Gazi Üniversitesi, Fen Bilimleri Enstitüsü.
- Balcıoğlu, Y. S., ve Sezen, B. (2024). K- En Yakın Komşu (KNN) ve MLP Yöntemi ile Hibrit Bir Sistem: Trafik Akış Tahmini. *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*, 26(4), 1801-1816. <https://doi.org/10.32709/akusosbil.1255897>
- Bardis, K., Avdelidis, N. P., Ibarra-Castaneda, C., Maldague, X. P. V., ve Fernandes, H. (2025). Advanced Diagnostics of Aircraft Structures Using Automated Non-Invasive Imaging Techniques: A Comprehensive Review. *Applied Sciences*, 15(7), 3584. <https://doi.org/10.3390/app15073584>
- Bartoszewski, B., Jarzyna, K., ve Baranowski, J. (2024). Diagnosis of Mechanical Rotor Faults in Drones Using Functional Gaussian Mixture Classifier. *Aerospace*, 11(9), 743. <https://doi.org/10.3390/aerospace11090743>
- Chen, P., Yan, S., Janicke, H., Mahboubi, A., Bui, H. T., Aboutorab, H., Bewong, M., ve Islam, R. (2025). A Survey on Unauthorized UAV Threats to Smart Farming. *Drones*, 9(4), 251. <https://doi.org/10.3390/drones9040251>
- Cinoğlu, B. (2024). Acoustic-based diagnostics for UAV propeller damage using HNR and Gaussian Naive Bayes. *Aircraft Engineering and Aerospace Technology*, 96(7), 972-982. <https://doi.org/10.1108/AEAT-05-2024-0155>

- Dhulipalla, A. (2025). *Experimental investigations to characterize detrimental effects of icing and rainfall on unmanned-aerial-vehicles (UAVs)*. Iowa State University.
- Eng Lim, P. A., ve Park, C. H. (2024). A Collaborative Ensemble Construction Method for Federated Random Forest. *Expert Systems with Applications*, 255, 124742. <https://doi.org/10.1016/j.eswa.2024.124742>
- Ercan, H., ve Dalkın, A. (2025). Full-Vehicle Experimental Investigation of Propeller Icing on a Hovering Quadcopter. *Drones*, 9(11), 729. <https://doi.org/10.3390/drones9110729>
- Ezzara, A., Ouadine, A. Y., ve Ayad, H. (2025). Adaptive Backstepping Sliding Mode Fault-Tolerant Control of Quadrotor UAV in the Presence of External Disturbances, Uncertainties, and Simultaneous Actuator and Sensor Faults. *International Journal of Computers Communications & Control*, 20(5). <https://doi.org/10.15837/ijccc.2025.5.7018>
- Farajijalal, M., Eslamiat, H., Avineni, V., Hettel, E., ve Lindsay, C. (2025). Safety Systems for Emergency Landing of Civilian Unmanned Aerial Vehicles (UAVs)—A Comprehensive Review. *Drones*, 9(2), 141. <https://doi.org/10.3390/drones9020141>
- Gao, H., Dekyi, D., ve Metok, M. (2025). Efficient unmanned aerial vehicle inspection and management of transmission lines in modern electric power enterprises. *Energy Informatics*, 8(1), 117. <https://doi.org/10.1186/s42162-025-00575-9>
- Gatkal, N. R., Nalawade, S. M., Bhanage, G. B., Sahni, R. K., Walunj, A. A., ve Kadam, P. B. (2025). Review of UAVs for efficient agrochemical spray application. *International Journal of Agricultural and Biological Engineering*, 18(1), 1-9. <https://doi.org/10.25165/j.ijabe.20251801.8979>
- Gemayel, A., Manias, D. M., ve Shami, A. (2025). *Network Resource Optimization for ML-Based UAV Condition Monitoring with Vibration Analysis* (arXiv:2502.15491). arXiv. <https://doi.org/10.48550/arXiv.2502.15491>
- Hale, E. (2022). *Frequency Analysis of UAV Vibration Anomalies Due to Wind*. NASA Langley Research Center.
- Holdbrook, R. (2025). *Fault Detection in Industrial and Robotics Systems Using Long Short-Term Memory (LSTM) with Simulated Data* [Yüksek Lisans Tezi]. NC A&T State University.
- Islam, M. S., Mahmoud, A. S., ve Sheltami, T. R. (2025). AI-Enhanced Intrusion Detection for UAV Systems: A Taxonomy and Comparative Review. *Drones*, 9(10), 682. <https://doi.org/10.3390/drones9100682>
- Jia, C., Xing, Y., Li, Z., ve Ge, X. (2025). A Novel Amphibious Terrestrial–Aerial UAV Based on Separation Cage Structure for Search and Rescue Missions. *Applied Sciences*, 15(16), 8792. <https://doi.org/10.3390/app15168792>

- João, K. (2025). *An Autonomous Robotic Inspection System for Underground Mines Using Unmanned Aerial Vehicles (UAVs)* [University of Kentucky Libraries]. <https://doi.org/10.13023/ETD.2025.322>
- Kalay, E., ve Özkul, İ. (2024). Role of Vibrations in Unmanned Aerial Vehicles, Efficiency Measurement Techniques, and Performance Impacts. *Türkiye İnsansız Hava Araçları Dergisi*, 6(2), 72-80. <https://doi.org/10.51534/tiha.1576860>
- Kantue, P., ve Pedro, J. O. (2022). Integrated fault-tolerant control of a quadcopter UAV with incipient actuator faults. *International Journal of Applied Mathematics and Computer Science*, 32(4). <https://doi.org/10.34768/amcs-2022-0042>
- Kaya, Z. (2025). Comparative Analysis of Neural Network Architectures for FFT Magnitude Spectrum Estimation. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 12(2), 681-692.
- Kılıç, C., Alçın, Ö. F., ve Aslan, M. (2025). Surface Textures Classification with Fractal Detrended Fluctuation Analysis. *Computer Science*, 10(2), 134-143. <https://doi.org/10.53070/bbd.1630805>
- Kishor, I., Mamodiya, U., Patil, V., ve Naik, N. (2025). AI-Integrated autonomous robotics for solar panel cleaning and predictive maintenance using drone and ground-based systems. *Scientific Reports*, 15(1), 32187. <https://doi.org/10.1038/s41598-025-17313-6>
- Koszewnik, A., Ambrożkiewicz, B., Oldziej, D., Dzienis, P., Pieciul, M., Syta, A., Zaburko, J., Bouattour, G., Gargasas, J., ve Bazienne, K. (2025). Structure analysis in an octocopter using piezoelectric sensors and machine learning. *Scientific Reports*, 15(1), 31776. <https://doi.org/10.1038/s41598-025-17265-x>
- Kumar, R. (2017). *Autonomous Control of Advanced Multirotor Unmanned Aerial Systems* [Doktora Tezi]. University of Cincinnati.
- Li, Y., ve Zhang, L. (2024). *A Novel Loss Function-based Support Vector Machine for Binary Classification* (arXiv:2403.16654). arXiv. <https://doi.org/10.48550/arXiv.2403.16654>
- Liu, W., Liu, C., Sajedi, S., Su, H., Liang, X., ve Zheng, M. (2024). An audio-based risky flight detection framework for quadrotors. *IET Cyber-Systems and Robotics*, 6(1), e12105. <https://doi.org/10.1049/csy2.12105>
- Makhtar, S. N., Samsuddin, M. D. A. M., Sani, F. Z. M., Nor, E. M., ve Bohari, B. (2024). Development of mobile indoor flight test rig for VTOL UAV application. *Journal of Physics: Conference Series*, 2928(1), 012002. <https://doi.org/10.1088/1742-6596/2928/1/012002>
- Mälzer, M., Simon, J., Günner, C., Del Rio Velilla, D., Rao, M., Beck, S., Memmolo, V., Moll, J., ve Krozer, V. (2025). Structural Health Monitoring of Aerial Vehicles Using Guided Electromagnetic Waves in K-Band: Initial Damage Detection Results from Drone Flight Testing. *Applied Sciences*, 15(12), 6478. <https://doi.org/10.3390/app15126478>

- Masalimov, K., Muslimov, T., Kozlov, E., ve Munasypov, R. (2024). CrazyPAD: A Dataset for Assessing the Impact of Structural Defects on Nano-Quadcopter Performance. *Data*, 9(6), 79. <https://doi.org/10.3390/data9060079>
- May, M., ve Strohbach, T. (2025). A review on collisions between drones and aerostructures – Experimental studies, numerical simulation, and regulation. *Defence Technology*, 51, 1-29. <https://doi.org/10.1016/j.dt.2025.04.011>
- Nayeem, N. M. (2025). *UAV States Estimation and Wind Field Reconstruction* [Yüksek Lisans Tezi]. Oklahoma State University.
- Nethamba, L., ve Grobbelaar, S. (2023). The Development of an Action Priority Matrix and Technology Roadmap for the Implementation of Data-Driven and Machine-Learning-Based Predictive Maintenance in the South African Railway Industry. *South African Journal of Industrial Engineering*, 34(3), 318-335. <https://doi.org/10.7166/34-3-2958>
- Okada, K. F. Á., Morais, A. S., Ribeiro, L., Amaral Da Luz, C. M., Tofoli, F. L., Lima, G. V., ve Lopes, L. C. O. (2024). Fault-Tolerant Control for Quadcopters Under Actuator and Sensor Faults. *Sensors*, 24(22), 7299. <https://doi.org/10.3390/s24227299>
- Pandya, S. (2025). *NMPC-based Unified Posture Manipulation and Thrust Vectoring for Agile and Fault-Tolerant Flight of a Morphing Aerial Robot* [Yüksek Lisans Tezi]. Northeastern University.
- Plastropoulos, A., Bardis, K., Yazigi, G., Avdelidis, N. P., ve Droznika, M. (2024). Aircraft Skin Machine Learning-Based Defect Detection and Size Estimation in Visual Inspections. *Technologies*, 12(9), 158. <https://doi.org/10.3390/technologies12090158>
- Poorghasem, S. (2025). *Multi-Scale Multi-Modal Monitoring of Structures Using AI-Powered Smart Sensors and Robots* [Doctor of Philosophy]. University of South Carolina.
- Qiu, Z., Zhang, L., Chi, Y., ve Li, Z. (2024). Active Obstacle Avoidance of Multi-Rotor UAV Swarm Based on Stress Matrix Formation Method. *Mathematics*, 13(1), 86. <https://doi.org/10.3390/math13010086>
- Rinaldi, J. (2025). *Serverless Federated Learning: Comparisons to FL and Vulnerabilities Under Fault Injection* [Yüksek Lisans Tezi]. North Carolina Agricultural and Technical State University.
- Soares, R. C., Silva, J. C., Pereira, M. B. P. N., Filho, A. C. L., Ramos, J. G. G. D. S., ve Brito, A. V. (2025). Development and evaluation of an ensemble neural network based methodology for rapid diagnosis and fault classification in unmanned aerial vehicles. *Neural Computing and Applications*, 37(5), 3943-3956. <https://doi.org/10.1007/s00521-024-10796-w>
- Sonmezocak, T. (2025). Intelligent UAV health monitoring: Detecting propeller and structural faults with MEMS-based vibration. *Engineering Science and*

Technology, an International Journal, 69, 102130.
<https://doi.org/10.1016/j.jestch.2025.102130>

- Sungur, F., ve Bakir, H. (2024). Hiperparametre ayarlama ve veri dengelemenin kalp hastalığı tahmini için kullanılan makine öğrenimi algoritmaları üzerindeki etkilerinin incelenmesi. *Bilişim Teknolojileri Dergisi*, 17(1), 45-58.
<https://doi.org/10.17671/gazibtd.1399813>
- Tiruvankadam, N., Gowri Shankar, S., Mahes Kumar, P., ve Gowtham, S. (2024). Investigation of Structural and Thermal Analysis of Drone Propeller Materials. *Journal of Physics: Conference Series*, 2925(1), 012002.
<https://doi.org/10.1088/1742-6596/2925/1/012002>
- Tong, J. J., Zhang, W., Liao, F., Li, C. F., ve Zhang, Y. F. (2021). *Machine Learning for UAV Propeller Fault Detection based on a Hybrid Data Generation Model*. Department of Mechanical Engineering, National University of Singapore & Temasek Laboratories, National University of Singapore. arXiv (2302.01556).
<https://doi.org/10.48550/arXiv.2302.01556>
- Torres, N. N. S., Maciel, J. N., Lima, T. L. D. V., Gazziro, M., Filho, A. C. L., Carmo, J. P. P. D., ve Ando Junior, O. H. (2025). Fault Diagnosis in Internal Combustion Engines Using Artificial Intelligence Predictive Models. *Applied System Innovation*, 8(5), 147. <https://doi.org/10.3390/asi8050147>
- Tunio, N. A., Tunio, M. A., Raza, M. A., Faheem, M., Hashmani, A. A., ve Nadeem, R. (2025). Performance Comparison Between Deep Learning Models for Fault Classification in Transmission Lines Using Time Series Data. *Energy Science & Engineering*, 13(5), 2330-2351. <https://doi.org/10.1002/ese3.70033>
- Wang, J., Frantz, J., Chumbley, E., Samad, A., ve Hu, H. (2025). An Explorative Study on Using Carbon Nanotube-Based Superhydrophobic Self-Heating Coatings for UAV Icing Protection. *Molecules*, 30(17), 3472.
<https://doi.org/10.3390/molecules30173472>
- Wang, K., Liu, Y., Guan, X., Wang, Z., Pan, Z., Yu, Y., Yao, Y., ve Li, T. (2025). Ultra-Wideband Detection-Enabled Modularized Three-Axis Vibration Sensor for UAV Blade Damage Monitoring via Deep Learning. *IEEE Transactions on Industrial Electronics*, 72(11), 11964-11974. <https://doi.org/10.1109/TIE.2025.3561854>
- Yaman, O. (2025). Development of a Closed-Loop PLM Application for Vibration-Based Structural Health Monitoring of UAVs. *Drones*, 9(11), 807.
<https://doi.org/10.3390/drones9110807>
- Yang, J., ve Mat, N. A. (2025). Machine learning based power insulation fault detection using unmanned aerial vehicle images: A systematic review. *Journal of Asian Scientific Research*, 15(3), 395-419. <https://doi.org/10.55493/5003.v15i3.5556>
- Yeom, J. (2025). *Active Fault-Tolerant Control of Quadrotors for Resilient and Safe Operations* [Doktora Tezi]. New York University, Tandon School of Engineering.

- Zhang, H., Ji, Y., Liu, T., Sun, X., ve Ball, A. D. (Ed.). (2023). *Proceedings of TEPEN 2022: Efficiency and Performance Engineering Network* (C. 129). Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-26193-0>
- Zhang, L., Gong, L., Wang, L., Wang, Z., ve Yan, S. (2025). A Building Crack Detection UAV System Based on Deep Learning and Linear Active Disturbance Rejection Control Algorithm. *Electronics*, 14(15), 2975. <https://doi.org/10.3390/electronics14152975>
- Zhang, W., Tong, J., Liao, F., ve Zhang, Y. (2025). Simulation-to-Reality Quadrotor Propeller Damage Detection in Windy Environments. *Unmanned Systems*, 1-12. <https://doi.org/10.1142/S2301385026500160>
- Zhong, Y., Chen, X., Li, P., Hou, P., Wang, Z., ve Nie, K. (2025). Active Fault-Tolerant Cooperative Control for Multi-QUAVs Using Relative Measurement Information. *Drones*, 9(10), 699. <https://doi.org/10.3390/drones9100699>
- Zou, Y., Xia, H., Yang, X., Li, P., ve Yi, Y. (2025). Dynamics Model of a Multi-Rotor UAV Propeller and Its Fault Detection. *Drones*, 9(3), 176. <https://doi.org/10.3390/drones9030176>