



**ELEKTRİKLİ HAVA ARACI İTKİ
SİSTEMLERİ İÇİN YAPAY ZEKA
DESTEKLİ AKILLI ALGILAMA**

Doktora Tezi

Bahadır CİNOĞLU

Eskişehir 2024

**ELEKTRİKLİ HAVA ARACI İTKİ SİSTEMLERİ İÇİN YAPAY ZEKA
DESTEKLİ AKILLI ALGILAMA**

Bahadır CİNOĞLU

Doktora Tezi

Havacılık Elektrik ve Elektronik Anabilim Dalı

Danışman: Prof. Dr. T. Hikmet KARAKOÇ

(İkinci Danışman: Prof. Dr. Umut DURAK)

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Temmuz 2024

Bu tez, TÜBİTAK komitesi tarafından kabul edilmiş 121N421 numaralı proje ile desteklenmiştir.

JÜRİ VE ENSTİTÜ ONAYI

Bahadır Cinoğlu'nun "Elektrikli Hava Aracı İtke Sistemleri İçin Yapay Zeka Destekli Akıllı Algılama" başlıklı tezi 08/07/2024 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Havacılık Elektrik ve Elektronik Anabilim dalında Doktora tezi olarak kabul edilmiştir.

<u>Jüri Üyeleri</u>	<u>Unvanı Adı Soyadı</u>	<u>İmza</u>
Üye (Tez Danışmanı)	: Prof. Dr. T. Hikmet KARAKOÇ	
Üye	: Prof. Dr. Melih C. KUŞHAN	
Üye	: Doç. Dr. Işıl YAZAR	
Üye	: Doç. Dr. Alper DALKIRAN	
Üye	: Dr. Öğr. Üyesi H. Ersin EROL	

Prof. Dr. Semra KURAMA

Lisansüstü Eğitim Enstitüsü Müdürü

08/07/2024

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Doktora đrencisi Bahadır CİNOđLU, ELEKTRİKLİ HAVA ARACI İTKİ SİSTEMLERİ İÇİN YAPAY ZEKA DESTEKLİ AKILLI ALGILAMA başlıklı tez çalışmasını tamamlamıştır. Hazırlamış olduđu tez tarafımda incelenmiş ve đrencinin tez savunma sınavına alınması bilimsel ve etik açıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. T. Hikmet KARAKOÇ

ÖZET

ELEKTRİKLİ HAVA ARACI İTKİ SİSTEMLERİ İÇİN YAPAY ZEKA DESTEKLİ AKILLI ALGILAMA

Bahadır CİNOĞLU

Havacılık Elektrik ve Elektronik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2024

Danışman: Prof. Dr. T. Hikmet KARAKOÇ

(İkinci Danışman: Prof. Dr. Umut DURAK)

Günümüzde hava araçlarının geleneksellikten uzaklaşarak alternatif yakıtlara yöneliyor olması, bu hava araçlarında kullanılan elektrikli itki sistemlerinin de artmasına ve araştırmacıların da bu konu üzerine yönelmesine neden olmuştur.

Çalışmada, İnsansız Hava Araçlarında (İHA) tabanlı metodolojilerin daha büyük, daha karmaşık sistemlere de uyarlanabileceği ve uygulanabileceği göz önüne alınarak, İHA'lar ile elektrikli hava araçları arasında köprü görevi görmek amaçlanmıştır. Bu doğrultuda yapılan çalışmalar ile ileri diagnostik tekniklerinin elektrikli uçak sistemlerinde uygulanabilmesine yönelik yapay zeka tabanlı bir yaklaşım sunulmuştur. Bu bağlamda, Model Tabanlı Sistem Mühendisliği (MBSE) ve Sistem Modelleme Dili (SysML) kullanılarak açık kaynaklı olacak şekilde kapsamlı bir İHA mimarisi geliştirilmiştir. Referans mimaride bulunan alt sistemlerden itki sistemi esas alınarak pervane hasarlarının algılanması için makine öğrenmesi ile bir akustik diyagnostik çalışması yapılmıştır. Sonrasında pervane hasarlarının titreşim verileri ile teşhis edilmesine yönelinmiş ve yapay sinir ağı kullanılarak titreşime bağlı diagnostik çalışma gerçekleştirilmiştir. Son adımda ise akustik ve titreşim verilerinin birlikte değerlendirildiği topluluk öğrenmesi metodolojisi kullanılarak model doğruluğunun artırılması hedeflenmiş ve bir akıllı algılama methodu geliştirilmiştir.

Çalışma, ileri tip diagnostik yöntemlerin elektrik uçak itki sistemlerine entegre edilmesi ile daha verimli, güvenilir ve emniyetli elektrikli uçakların geliştirilmesine katkı sağlamayı amaçlamaktadır.

Keywords: Yapay zeka, İHA, Hata teşhis, Özellik çıkarımı, MBSE

ABSTRACT

ARTIFICIAL INTELLIGENCE BASED SMART SENSING FOR ELECTRIC AIRCRAFT PROPULSION

Bahadır CİNOĞLU

Department of Avionics

Eskişehir Technical University, Institute of Graduate Programs, July 2024

Supervisor: Prof. Dr. T. Hikmet KARAKOÇ

(Co-Supervisor: Prof. Dr. Umut DURAK)

Lately, the preference of alternative fuels for aircrafts by diverging from traditionality has caused an increased percentage of electrified propulsion systems, encouraging scientific studies to target this research topic in particular.

The purpose of this study is to bridge the gap between Unmanned Aerial Vehicles and electric aircrafts, taking into consideration the applicability and adaptability of UAV-based methodologies to more complicated systems. Studies done in this context provided an artificial intelligence-based approach for applicable advanced diagnostic techniques in electric aircraft. Concordantly, a comprehensive open-sourced UAV architecture was developed by using Model-Based Systems Engineering (MBSE) and System Modelling Language (SysML). A propulsion system that is found in the sub-systems of reference architecture allowed an acoustics diagnostics study for detecting propeller damage through machine learning. Following that; damaged propellers were identified via vibration data and a vibration-based diagnostic study was conducted by implementing an artificial neural network. The final part involved increasing the model accuracy by utilizing an ensemble learning methodology that is evaluating the acoustic and vibration data holistically and developing and smart sensing method.

One of the aims of this study is to contribute to the manufacturing more optimized, more secure and safe electric aircraft through the integration of advanced diagnostic methods into propulsion systems.

Keywords: Artificial intelligence, UAVs, Diagnostics, Feature extraction, MBSE

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesi esnasında her konuda desteklerini gösteren ve sağlamış oldukları olanaklar ile akademik gelişimime ve dünya görüşüme çok büyük katılar sunan tez danışmanlarım Prof. Dr. T. Hikmet KARAKOÇ ve Prof. Dr. Umut Durak başta olmak üzere, ortaya konmuş olan çalışmanın her adımında yer alan ve fikirleri, eleştirileri ve düşünceleri ile ilgili çalışmanın başarılı bir şekilde tamamlanmasına olan katkılarından ötürü değerli tez izleme komitesi üyeleri Doç. Dr. Işıl YAZAR ve Doç. Dr. Alper DALKIRAN'a, tüm doktora süreci boyunca her konuda vermiş olduğu sonsuz destek ile çalışmalarına karşı olan inancımı korumamı sağlayan Öğr. Gör. Özge KÜÇÜKKÖR'e sonsuz teşekkürlerimi sunarım.

Ayrıca, hayatım boyunca her konuda yanımda olan ve hayatta karşılaştığım tüm engellerde bana destek veren, yol gösteren ve fikirlerime saygı duyan değerli anne ve babam Nesrin CİNOĞLU ve Turgut CİNOĞLU'na sevgi ve saygılarımı sunuyorum.

Bahadır CİNOĞLU

Eskişehir, 2024

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Bahadır CİNOĞLU

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
DANIŞMAN ONAYI	iii
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR	vi
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vii
İÇİNDEKİLER.....	viii
TABLolar DİZİNİ.....	xii
ŞEKİLLER DİZİNİ.....	xiii
GÖRSELLER DİZİNİ	xviii
SİMGELER VE KISALTMALAR DİZİNİ.....	xix
1. GİRİŞ.....	1
1.1. Literatür Taraması	3
2. ELEKTRİKLİ HAVA ARACININ MODELLENMESİ	31
2.1. Model Tabanlı Sistem Mühendisliği (MBSE).....	31
2.1.1. Modelleme dili.....	34
2.2. Hava Aracı Modelinin Oluşturulması.....	35
2.2.1. Fiziksel büyüklükler ve veri tipleri	37
2.2.1.1. İtki sistemi değer tipleri	38
2.2.1.2 Kontrol sistemi değer tipleri	41
2.2.1.3. Emniyet ve alarm sistemi değer tipleri	43
2.2.1.4. Uçuş kontrol sistemi değer tipleri	45
2.2.1.5. Güç sistemi değer tipleri.....	46
2.2.1.6. Sensörler değer tipleri	48
2.2.1.7. Aviyonikler değer tipleri.....	50

2.2.2. Blok tanım diyagramları.....	54
2.2.2.1. Genel sistem mimarisi BDD.....	54
2.2.2.2. İtke sistemi BDD	55
2.2.2.3. Kontrol sistemi BDD	56
2.2.2.4. Emniyet ve alarm sistemi BDD.....	56
2.2.2.5. Uçuş kontrol sistemi BDD.....	57
2.2.2.6. Güç sistemi BDD	57
2.2.2.7. Sensörler BDD.....	58
2.2.2.8. Aviyonikler BDD	58
2.2.3. Gereksinim diyagramları.....	59
2.2.3.1. İtke sistemi RD	59
2.2.3.2. Kontrol sistemi RD	63
2.2.3.3. Emniyet ve alarm sistemi RD.....	71
2.2.3.4. Uçuş kontrol sistemi RD	74
2.2.3.5. Güç sistemi RD	79
2.2.3.6. Sensörler RD	83
2.2.3.7. Aviyonikler RD	99
2.2.4. İç blok diyagramları.....	109
2.2.4.1. Genel sistem mimarisi IBD	109
2.2.4.2. İtke sistemi IBD.....	110
2.2.4.3. Kontrol sistemi IBD.....	110
2.2.4.4. Emniyet ve alarm sistemi IBD	110
2.2.4.5. Uçuş kontrol sistemi IBD	111
2.2.4.6. Güç sistemi IBD	111
2.2.4.7. Sensörler IBD	113
2.2.4.8. Aviyonikler IBD.....	113
2.2.5. Kullanım Senaryosu diyagramları.....	115
2.2.5.1. Genel sistem mimarisi UCD.....	117
2.2.5.2. İtke sistemi UCD	118
2.2.5.3. Kontrol sistemi UCD	120
2.2.5.4. Emniyet ve alarm sistemi UCD.....	120
2.2.5.5. Uçuş kontrol sistemi UCD.....	121

2.2.5.6. Güç sistemi UCD	122
2.2.5.7. Sensörler UCD.....	123
2.2.5.8. Aviyonikler UCD	124
3. YAPAY ZEKA DESTEKLİ AKUSTİK DİAGNOSTİK	127
3.1. Ekipmanlar ve Test Ortamı	127
3.2. Yöntem	132
3.2.1. Mel-Frequency Cepstral Coefficients (MFCC)	133
3.2.2. Random Forest.....	136
3.2.3. Veri toplama.....	137
3.2.4. Feature Importance (FI)	142
3.2.5. Receiver Operating Characteristic (ROC).....	142
3.2.5.1. Gerçek Pozitif Oranı (TPR)	143
3.2.5.2. Yanlış Pozitif Oranı (FPR)	143
3.2.6. Karmaşıklık Matrisi	143
3.2.6.1. Precision	144
3.2.6.2. Recall	144
3.2.6.3. Accuracy	144
3.2.6.4. F-1 Score	144
4. YAPAY SİNİR AĞI İLE TİTREŞİME BAĞLI DİAGNOSTİK	145
4.1. Ekipmanlar ve Test Ortamı	145
4.2. Yöntem	149
4.2.1. Veri Toplama	149
4.2.2. İstatistiksel özellik çıkarımı ve Z-Score normalizasyonu	151
4.2.2.1. Ortalama Değer	151
4.2.2.2. Orta Değer	151
4.2.2.3. Standart Sapma	152
4.2.2.4. Skewness	152
4.2.2.5. Kurtosis	153
4.2.3. İleri yönlü yapay sinir ağı (FFNN).....	154

5. TOPLULUK ÖĞRENMESİ MODELİ İLE AKILLI ALGILAMA.....	159
5.1. Yöntem	160
6. BULGULAR.....	163
6.1. Akustik Diyagnostik.....	163
6.2. Titreşime Bağlı Diyagnostik	166
6.3. Akıllı Algılama.....	170
6.3.1. Akustik model performansı.....	171
6.3.2. Titreşim modeli performansı.....	172
6.3.3. Topluluk öğrenmesi modeli performansı	174
7. SONUÇLAR.....	176
KAYNAKÇA.....	182
EKLER	
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1. ADXL345 Teknik Özellikleri	146
--	-----



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Fiziksel birimlerin tanımlanması.....	37
Şekil 2.2. Pervane değer tipinde fiziksel birimlerin kullanılması.....	37
Şekil 2.3. Elektrik motoru Integer değer tipi	38
Şekil 2.4. Elektrik motoru Real değer tipleri.....	39
Şekil 2.5. ESC Integer değer tipleri.....	39
Şekil 2.6. ESC Real değer tipleri.....	40
Şekil 2.7. Pervane real değer tipleri.....	40
Şekil 2.8. Kontrol yüzeyleri değer tipleri	41
Şekil 2.9. Aktüatör değer tipleri	42
Şekil 2.10. Aktüatör kontrolcüsü Integer değer tipleri	42
Şekil 2.11. Aktüatör kontrolcüsü Real değer tipleri	43
Şekil 2.12. Emniyet ve alarm sistemi Integer değer tipleri	44
Şekil 2.13. Emniyet ve alarm sistemi Boolean ve Real değer tipleri	44
Şekil 2.14. Uçuş kontrolcüsü Integer ve Real değer tipleri	45
Şekil 2.15. Uçuş kontrol bilgisayarı Integer değer tipleri.....	46
Şekil 2.16. Uçuş kontrol bilgisayarı Real değer tipleri.....	46
Şekil 2.17. Batarya Integer değer tipleri.....	47
Şekil 2.18. Batarya Real değer tipleri.....	47
Şekil 2.19. Güç modülü Integer değer tipleri	48
Şekil 2.20. Güç modülü Real değer tipleri	48
Şekil 2.21. Sensörler Integer değer tipleri	49
Şekil 2.22. Sensörler Real değer tipleri	49
Şekil 2.23. Sensörler String değer tipleri.....	50
Şekil 2.24. Telemetri değer tipleri	51

Şekil 2.25. Kamera değer tipleri	51
Şekil 2.26. Radyo kontrol alıcısı Integer değer tipleri.....	52
Şekil 2.27. Radyo kontrol alıcısı Boolean ve Real değer tipleri.....	53
Şekil 2.28. Radyo kontrol alıcısı “Radyo Kontrol Sinyali” değer tipi	53
Şekil 2.29. Mikrofon değer tipleri	54
Şekil 2.30. Genel sistem mimarisi BDD diyagramı	55
Şekil 2.31. İtki Sistemi BDD diyagramı.....	55
Şekil 2.32. Kontrol sistemi BDD diyagramı.....	56
Şekil 2.33. Emniyet ve alarm sistemi BDD diyagramı.....	56
Şekil 2.34. Uçuş kontrol sistemi BDD diyagramı	57
Şekil 2.35. Güç sistemi BDD diyagramı	58
Şekil 2.36. Sensörler BDD diyagramı	58
Şekil 2.37. Aviyonikler BDD diyagramı	59
Şekil 2.38. Motorun yapısal gereksinimler.....	60
Şekil 2.39. Motorun yapısal olmayan gereksinimleri.....	60
Şekil 2.40. Pervanenin yapısal gereksinimleri.....	61
Şekil 2.41. Pervanenin yapısal olmayan gereksinimleri.....	62
Şekil 2.42. Aileron’un yapısal gereksinimleri	64
Şekil 2.43. Aileron’un fonksiyonel gereksinimleri	65
Şekil 2.44. Aktüatörün yapısal gereksinimleri	67
Şekil 2.45. Aktüatörün fonksiyonel gereksinimleri.....	68
Şekil 2.46. Aktüatör kontrolcüsünün fonksiyonel gereksinimleri.....	69
Şekil 2.47. Aktüatör kontrolcüsünün emniyet gereksinimleri.....	69
Şekil 2.48. Aktüatör kontrolcüsünün performans gereksinimleri.....	70
Şekil 2.49. Buzzer’ın yapısal ve fonksiyonel gereksinimleri	71
Şekil 2.50. Buzzer’ın yapısal olmayan gereksinimleri	71
Şekil 2.51. Arm switch’in yapısal olmayan gereksinimleri.....	72

Şekil 2.52. Arm Switch'in fonksiyonel gereksinimleri	73
Şekil 2.53. Arm switch'in fonksiyonel olmayan gereksinimleri	74
Şekil 2.54. Uçuş kontrol bilgisayarının yapısal gereksinimleri.....	75
Şekil 2.55. Uçuş kontrol bilgisayarının fonksiyonel gereksinimleri	76
Şekil 2.56. Uçuş kontrol bilgisayarının yapısal olmayan gereksinimleri	78
Şekil 2.57. Bataryanın yapısal gereksinimleri	80
Şekil 2.58. Bataryanın yapısal olmayan gereksinimleri	81
Şekil 2.59. Güç modülü RD diyagramı	82
Şekil 2.60. IMU gereksinimleri	84
Şekil 2.61. Barometrenin yapısal gereksinimleri.....	87
Şekil 2.62. Barometrenin fonksiyonel gereksinimleri	89
Şekil 2.63. GPS'in yapısal gereksinimleri.....	90
Şekil 2.64. GPS'in fonksiyonel gereksinimleri	91
Şekil 2.65. GPS'in yapısal olmayan gereksinimleri	93
Şekil 2.66. Manyetometrenin yapısal gereksinimleri	93
Şekil 2.67. Manyetometrenin fonksiyonel gereksinimleri.....	94
Şekil 2.68. Manyetometrenin fonksiyonel olmayan gereksinimleri.....	95
Şekil 2.69. Hava hızı sensörünün yapısal gereksinimleri	95
Şekil 2.70. Hava hızı sensörünün fonksiyonel gereksinimleri	96
Şekil 2.71. Hava hızı sensörünün fonksiyonel olmayan gereksinimleri.....	97
Şekil 2.72. Ultrasonik sensörün yapısal gereksinimleri	97
Şekil 2.73. Ultrasonik sensörün fonksiyonel gereksinimleri.....	98
Şekil 2.74. Ultrasonik sensörün fonksiyonel olmayan gereksinimleri	99
Şekil 2.75. Telemetrinin yapısal gereksinimleri	100
Şekil 2.76. Telemetrinin yapısal olmayan gereksinimleri	100
Şekil 2.77. Telemetrinin fonksiyonel gereksinimleri	101
Şekil 2.78. Telemetrinin fonksiyonel olmayan gereksinimleri.....	102

Şekil 2.79. Kameranın yapısal gereksinimleri.....	102
Şekil 2.80. Kameranın fonksiyonel gereksinimleri	103
Şekil 2.81. Kameranın fonksiyonel olmayan gereksinimleri	104
Şekil 2.82. Radyo kontrol alıcısının yapısal gereksinimleri	105
Şekil 2.83. Radyo kontrol alıcısının fonksiyonel gereksinimleri	106
Şekil 2.84. Radyo kontrol alıcısının fonksiyonel olmayan gereksinimleri.....	107
Şekil 2.85. Mikrofon RD diyagramı	108
Şekil 2.86. Emniyet ve alarm sistemi IBD	111
Şekil 2.87. Güç sistemi IBD diyagramı	112
Şekil 2.88. Aviyonikler IBD diyagramı.....	114
Şekil 2.89. Genel sistem mimarisi UCD diyagramı	118
Şekil 2.90. İtki sistemi UCD diyagramı	119
Şekil 2.91. Kontrol sistemi UCD diyagramı.....	120
Şekil 2.92. Emniyet ve alarm sistemi UCD diyagramı.....	121
Şekil 2.93. Güç sistemi UCD diyagramı	123
Şekil 2.94. Sensörler UCD diyagramı	124
Şekil 2.95. Aviyonikler UCD diyagramı	125
Şekil 3.1. Pervane hasarları	128
Şekil 3.2. İşlenmemiş ses kaydı örneği.....	132
Şekil 3.3. Pervane tiplerine göre ses kayıtları	138
Şekil 3.4. Görselleştirilmiş MFCC özellik çıkarımı verileri	140
Şekil 3.5. MFCC özellik çıkarımı verileri.....	141
Şekil 4.1. Üç eksenli titreşim örneği.....	149
Şekil 4.2. Pervane tiplerine göre titreşim kayıtları	150
Şekil 4.3. Model eğitiminde kullanılan FFNN	155
Şekil 5.1. Akıllı algılama eğitim akışı	161
Şekil 6.1. AI modelin FI değerlendirme sonuçları	164

Şekil 6.2. AI modelin ROC değerlendirme sonuçları.....	165
Şekil 6.3. AI modelin karmaşıklık matrisi değerlendirme sonuçları	165
Şekil 6.4. FFNN modelinin karmaşıklık matrisi değerlendirme sonuçları.....	168
Şekil 6.5. AI modelin ROC değerlendirme sonuçları.....	170
Şekil 6.6. Z-Score normalizasyonu sonrası akustik verilerin karmaşıklık matrisi	171
Şekil 6.7. Z-Score normalizasyonu sonrası akustik verilere ait ROC	172
Şekil 6.8. Rastgele seçilmiş veriler ile FFNN karmaşıklık matrisi	173
Şekil 6.9. Rastgele seçilmiş veriler ile FFNN'ye ait ROC	173
Şekil 6.10. Topluluk öğrenmesi karmaşıklık matrisi.....	174
Şekil 6.11. Topluluk öğrenmesi ROC grafiği.....	175

GÖRSELLER DİZİNİ

	<u>Sayfa</u>
Görsel 3.1. Fırçasız motor	128
Görsel 3.2. LiPo batarya.....	129
Görsel 3.3. Elektronik hız kontrolcüsü	129
Görsel 3.4. Radyo kontrol alıcısı.....	130
Görsel 3.5. RC Kumanda	130
Görsel 3.6. USB Mikrofon	131
Görsel 3.7. Test düzeneği.....	131
Görsel 4.1. ADXL345 IMU sensörü	146
Görsel 4.2. Arduino Uno	147
Görsel 4.3. ADXL345-Arduino bağlantısı.....	147
Görsel 4.4. Titreşim sensörü konumu	148
Görsel 4.5. Titreşim sensörü test düzeneği	148

SİMGELER VE KISALTMALAR DİZİNİ

V	: Volt
A	: Amper
μ	: Ortalama Değer
Σ	: Standart Sapma
σ^2	: Varyans
AADL	: Architectural Analysis Design Language (Mimari Analiz Tasarım Dili)
ADAM	: Adaptive Moment Estimation (Uyarlanabilir Moment Tahmini)
ADS	: Air Data System (Hava Veri Sistemi)
AI	: Artificial Intelligence (Yapay Zeka)
ANFIS	: Adaptive Neuro-Fuzzy Inference System (Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
ARIMA	: Autoregressive Integrated Moving Average (Otoregresif Entegre Hareketli Ortalama)
ART	: Adaptive Resonance Theory (Adaptif Rezonans Teorisi)
AUC	: Area Under the Curve (Eğrinin Altındaki Alan)
BDD	: Block Definition Diagrams (Blok Tanım Diyagramları)
CART	: Classification and Regression Tree (Sınıflandırma ve Regresyon Ağacı)
CG	: Center of Gravity (Ağırlık Merkezi)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
CPU	: Central Processing Unit (İşlemci)
CRNN	: Convolutional Recurrent Neural Network (Evrişimsel Tekrarlayan Sinir Ağı)
CSV	: Comma Separated Values (Virgülle Ayrılmış Değerler)
CTBFE	: Central Tendency-Based Feature Extraction (Merkezi Eğilim Tabanlı Özellik Çıkarma)
DC	: Direct Current (Doğru Akım)

DCNN	: Deep Convolutional Neural Network (Derin Evriřimli Sinir Ađı)
DCT	: Discrete Cosine Transform (Ayrık Kosinüs Dönüşümü)
DD-CNN	: Difference Based Deep Convolutional Neural Network (Fark Tabanlı Derin Evriřimli Sinir Ađı)
DEPM	: Dual-graph Error Propagation Model (Çift Grafik Hata Yayılım Modeli)
DNN	: Deep Neural Network (Derin Sinir Ađı)
DT	: Decision Tree (Karar Ađacı)
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
EASA	: European Union Aviation Safety Agency (Avrupa Birliđi Havacılık Güvenliđi Ajansı)
EMA	: Experimental Modal Analysis (Deneyisel Modal Analiz)
EMD	: Empirical Mode Decomposition (Ampirik Mod Ayırıştırması)
EMI	: Electromagnetic Interference (Elektromanyetik Parazit)
ESC	: Electronic Speed Controller (Elektronik Hız Kontrolcüsü)
eVTOL	: Electric Vertical Take-Off And Landing (Elektrikli Dikey Kalkış ve İniř)
FASTER	: Fault and State Detection of Rotary Machineries (Döner Makinelerin Arıza ve Durum Tespiti)
FCC	: Flight Control Computer (Uçuř Kontrol Bilgisayarı)
FDI	: Fault Detection and Identification (Hata Tespit ve Tanımlama)
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
FI	: Feature Importance
FIR	: Finite Impulse Response (Sonlu Darbe Tepkisi)
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
FPR	: False Positive Ratio (Yanlış Pozitif Oranı)
GA	: Genetics Algoritm (Genetik Algoritma)
GDBM	: Gaussian-Bernoulli Deep Boltzmann Machine (Gauss-Bernoulli Derin Boltzmann Makinesi)

GHz	: Giga Hertz
GMM	: Gaussian Mixture Model (Gauss Karışım Modeli)
GPS	: Global Positioning System (Küresel Konumlandırma Sistemi)
GRBM	: Gaussian-Bernoulli Restricted Boltzmann Machines (Gauss-Bernoulli Kısıtlı Boltzmann makineleri)
HNR	: Harmonic to Noise Ratio (Harmonik-Ses Oranı)
IBD	: Internal Block Diagrams (İç Blok Diyagramları)
ICAO	: International Civil Aviation Organization (Uluslararası Sivil Havacılık Örgütü)
IDE	: Integrated Development Environment (Geliştirme Ortamı)
IMU	: Inertial Measurement Unit (Atalet Ölçüm Birimi)
IoT	: Internet of Things (Nesnelerin İnterneti)
İHA	: İnsansız Hava Aracı
JPL	: Jet Propulsion Laboratory
Km	: Kilometer (Kilometre)
KNN	: K-Nearest Neighbour (K-En Yakın Komşu)
LDA	: Linear Discriminant Analysis (Doğrusal Diskriminant Analiz)
LiPo	: Lithium Polymer (Lityum Polimer)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
mAh	: Milliampere-Hour (Miliamper-Saat)
MBSE	: Model-Based Systems Engineering (Model Tabanlı Sistem Mühendisliği)
MCSA	: Motor Current Signature Analysis (Motor Akım İmza Analizi)
MEMS	: Micro-Electro-Mechanical Systems (Mikro-Elektro-Mekanik Sistemler)
MFCC	: Mel-Frequency Cepstral Coefficients (Mel-Frekans Cepstral Katsayıları)
MoBIE	: Model-Based Interoperability Engineering (Model Tabanlı Birlikte Çalışabilirlik Mühendisliği)
ms	: Miliseconds (Milisaniye)

MSD	: Mass-Spring-Damper (Kütle-Yay-Sönümleyici)
MTOW	: Maximum Takeoff Weight (Maksimum Kalkış Ağırlığı)
NM	: Nearest Mean Classifier (En Yakın Ortalama)
OASPL	: Overall Sound Pressure Level (Genel Ses Basıncı Seviyesi)
OMA	: Operational Modal Analysis (Operasyonel Modal Analiz)
PCA	: Principal Component Analysis
PKL	: Python Pickle
PSD	: Power Spectral Density (Güç Spektral Yoğunluğu)
PSF	: Parallel Sparse Filtering (Paralel Seyrek Filtreleme)
PWM	: Pulse Width Modulation (Sinyal Genişlik Modülasyonu)
QFDC	: Quadcopter Failure Detection Clusters (Quadcopter Arıza Tespit kümeleri)
RC	: Radio Control (Radyo Kontrol)
RD	: Requirements Diagrams (Gereksinim Diyagramları)
RELU	: Rectified Linear Unit (Rektifiye Lineer Birim)
RFI	: Radio-Frequency Interference (Radyo-Frekans Paraziti)
RMS	: Root Mean Square
RMSE	: Root Mean Square Error (Ortalama Karekök Hatası)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROC	: Receiver Operating Characteristic
RPM	: Revolutions Per Minute (Dakikadaki Devir Sayısı)
SLIM	: Systems Lifecycle Management (Sistemlerin Yaşam Döngüsü Yönetimi)
SoC	: State of Charge (Şarj Durumu)
SoH	: State of Health (Sağlık Durumu)
SoS	: Systems of Systems (Sistemlerin Sistemleri)

SPL	: Sound Pressure Level (Ses Basıncı Seviyesi)
STFT	: Short-Time Fourier Transform (Kısa Zamanlı Fourier Dönüşümü)
SVM	: Support Vector Machines (Destek Vektör Makineleri)
SVMM	: Spatial Vibration Modulation Method (Uzaysal Titreşim Modülasyon Metodu)
SWL	: Sound Power Level (Ses Gücü Seviyesi)
SysML	: System Modelling Language (Sistem Modelleme Dili)
TN	: True Negative (Doğru Negatif)
TP	: True Positive (Gerçek Pozitif)
TPR	: True Positive Ratio (Gerçek Pozitif Oranı)
TrEnc	: Transformer Encoder (Dönüştürücü Kodlayıcı)
TR-LDA	: Trace Ratio Linear Discriminant Analysis (İz Oranı Doğrusal Diskriminant Analizi)
UAS	: Unmanned Aircraft Systems (İnsansız Hava Aracı Sistemleri)
UCD	: Use Case Diagrams (Kullanım Senaryosu Diyagramları)
UML	: Unified Modelling Language (Birleşik Modelleme Dili)
USB	: Universal Serial Bus (Evrensel Seri Veriyolu)
VSA	: Vibration Signature Analysis (Titreşim İmza Analizi)
VTOL	: Vertical Take-Off and Landing (Dikey Kalkış ve İniş)
WPD	: Wavelet Packet Decomposition (Dalgacık Paket Ayırıştırması)

1. GİRİŞ

Günümüz hava araçlarının elektrik sistemlerinin artan karmaşıklığı ve sistemlerinin kritikliği bu araçlardaki kritik ekipman ve süreçleri izlemek, tanı-teşhis yapmak ve sistem kararlılığının kestirimini yapmak anlamında modern çözümlere olan ihtiyacı her zamankinden daha da fazla arttırmıştır. Özellikle son yıllarda Uluslararası Sivil Havacılık Örgütü'nün (ICAO) ortaya koymuş olduğu karbon salınımının azaltılması hedefleri sonrasında elektrikli motorlara sahip hava araçları konseptleri ortaya çıkmaya başlamıştır. Henüz mevcut teknoloji ile tam olarak elektrik ile çalışan ticari hava araçları yaygınlaşmamış olsa da bu konudaki çalışmalar özellikle son yıllarda kullanımı artmış olan ve literatürde çok fazla araştırma konusu olan İnsansız Hava araçlarına (İHA) yönelmiş ve bu tip araçlar teknolojik gelişmeler için bir basamak haline gelerek geleceğin sürdürülebilir havacılığına önemli katkılarda bulunmaya başlamıştır. Ancak, bu tip hava araçlarının geliştirilmesinde kullanılabilecek ekipmanların fazlalığı ve emniyet anlamında kritik sistemlerin etkin bir şekilde oluşturulması tüm sistem ve alt sistemler hakkında kapsamlı bilgi sahibi olmayı gerektirmektedir. Çünkü kullanılabilecek her ekipmanın dikkat edilmesi gereken şartları, çalışma ile ilgili veya operasyonel anlamdaki sınırlamaları, çevresel şartlara bağlı olarak değişen gereksinimleri olmakta veya bu sistemlerden elde edilen veriler ile güncel teknolojileri kullanarak etkin bir şekilde başa çıkabilme durumu tamamen ilgili sistem veya alt sistemin anlaşılabilirliği ile doğrudan ilişkili olmaktadır.

Sistem anlaşılabilirliğini sağlamanın en etkili yollarından biri, henüz ilgili sistem veya alt sistem oluşturulurken, belirli kalıplar üzerinden ekipmanların birbirleri ile olan etkileşimlerini, kullanım esnasındaki gereksinimlerini ve diğer ekipmanlar ile etkileşimlerinin açık bir şekilde ortaya konmasıdır. Bu durumu sağlamanın ve sistem karmaşıklığından kaçınılarak tüm sisteme genel bir bakış atmanın yollarından biri sistem mühendisliği kavramlarını kullanmaktır. Böylece, hem donanımsal anlamda sistem içerisindeki ilişkiler anlaşılabilir ve karmaşıklıktan uzak bir şekilde ortaya konabilir. Ayrıca, bahsedilmiş olan sistem karmaşıklığı sürekli gelişmekte olan bu tip hava araçlarında her yeni uygulama ile birlikte biraz daha artmaktadır. Özellikle uzak mesafelerde kullanılan İHA'ların hem operasyonel hem sistemsal olarak sürekli kontrol edilmesi konusu yeni gereksinimler, yöntemler ve trendlerin çıkmasına sebep olmuş ve bu konulardaki eğilim daha çok tam veya yarı otonom modda çalışmaya doğru yönelmiştir.

Otonomluğun bu şekilde dahil edilmesi, otonom operasyonlar kapsamında güvenliğin sistem operasyonlarına dahil edilmesi için kritik bir ihtiyacı ortaya çıkarmaktadır. Çünkü sistem veya bir alt sistemdeki en ufak iyileştirme hava aracının geneline etki etmekte ve güvenilirlik, güvenlik ve verimlilik anlamında mevcut durumu bir adım daha öteye taşımaktadır.

Otonom bir elektrikli araç, misyonunu başarıyla tamamlamak için mevcut sağlık durumu hakkında doğru tahminlerde bulunabilmeli ve kritik kararları zamanında vermek için doğru kestirimlerde bulunabilmelidir. Bu durum hava aracının hedefine güvenli ve başarılı bir şekilde ulaşabilmesi için elektrikli itki sistemi gibi kritik sistemlerinin sağlık durumunu değerlendirmeyi gerektirmektedir. Bunun için, diagnostik uygulamalar ile sistemin veya sensörün mevcut durumu değerlendirilerek sağlıklı çalışması ile ilgili ortada bir sorun olup olmadığı kontrol edilir.

Diğer yandan, diagnostik uygulamalarında sistemlerin mevcut durumlarının belirlenmesinde yazılım teknolojileri şüphesiz ki en öne çıkan unsurlardan biridir. Özellikle otonom bir sistemden bahsedildiği zaman, diagnostik uygulamaların sistem içerisinde otonom bir şekilde değerlendirilmesi ve ele alınması konusu ön plana çıkmakta ve günümüzde bu otonomluk kendini sistemlerde yapay zeka (AI) kullanımına doğru yönelim ile belli etmektedir.

Son yıllarda bilgisayar donanımlarında yaşanan gelişmeler ve bu gelişmelerin donanımsal kısıtlamaları azaltması sonucunda önemli ölçüde sistem kaynağına ihtiyaç duyan AI konusu trend olmuş ve günümüzde bir çok otomobil şirketi hali hazırda içerisinde AI barındıran araçları piyasaya sürmüştür. AI'ın hayatın birçok alanında olduğu gibi araştırmacılar tarafından hava araçlarında da kullanılmak istenmesi ve sürekli artan literatür çalışması sonucunda geçen yıllarda Avrupa Birliği Havacılık Güvenliği Ajansı (EASA)'nın yayınlamış olduğu "EASA Yapay Zeka Yol Haritası 1.0" (EASA Artificial Intelligence Roadmap 1.0) ile AI'ın hava araçlarında ilk adımda asistan olarak kullanılmasının yolu açılmış olmuştur. EASA yayınladığı yol haritasını yılda bir kez değiştirilecek ve görüş alışverişi yoluyla ve ajansın halihazırda dahil olduğu AI geliştirme üzerine pratik çalışmalar yoluyla artırılacak, derinleştirilecek ve iyileştirilecek canlı bir belgedir." şeklinde tanımlamaktadır. Bu tanımdan da anlaşılacağı üzere, hava araçlarında AI kullanımının gün geçtikçe artması beklenmekte ve konu üzerine çalışmalar sürekli devam etmektedir.

Tez çalışmasında öncelikle açık kaynak kodlu olması hedeflenen ve araştırmacılara ve konu ile ilgilenen kişilere referans olması için bir hava aracı sistem mühendisliği kavramı benimsenerek modellenmiş, böylelikle sistem karmaşıklığından soyutlanarak referans bir mimari oluşturulmaya çalışılmıştır. Sonrasında hava aracı sistemlerinde güvenlik ve güvenilirliği konusunda kritik öneme sahip hata teşhisi konusu ile ilgili diagnostik yaklaşımlar ile ilgili yapılmış olan literatürdeki çalışmalara yer verilmiş ve oluşturulmuş olan referans elektrikli hava aracı mimarisinde belirtilen itki sistemi için AI destekli akıllı algılama uygulaması hakkında çalışmalar yapılmıştır.

1.1. Literatür Taraması

Peciak vd, spor uçuşu, pilot eğitimi gibi faaliyetler için kullanılacak elektrikli uçakların Model Tabanlı Sistem Mühendisliği (MBSE) kavramı ile çeşitli senaryolarda kullanım olasılıklarını analiz etmişlerdir. Çalışmada, MATLAB/Simulink'te üç farklı görev için simülasyon modelleri geliştirmişlerdir. Bu üç farklı görev, ülkeler arası uçuş, touch and go, ve planör çekme görevlerinden oluşmaktadır. Analiz için farklı sınıfları temsil eden üç uçak seçilmiştir. Bunlar, Diamond DA20 Katana, WT-9 Dynamic ve PZL-101 Gawron olmuştur. Her görev için gereksinimler, pilotlardan toplanan verilere ve halka açık uçuş kayıtlarına göre belirlenmiştir. İncelenen uçağın elektrikli itki sistemine güç sağlayan batarya sayısı, uçağın mevcut yapısında herhangi değişikliğe gerek kalmayacak ve maksimum kalkış ağırlığını (MTOW) aşmayacak şekilde seçilmiştir. Yapmış oldukları çalışma sonucunda küçük elektrikli uçakların havalimanlarının yakınında gerçekleştirilen uçuşlarda, touch and go prosedürlerinin gerçekleştirilmesinde ve planörlerin çekilmesinde kullanılabileceğini belirtmişlerdir [1].

Mordecai vd., Model Tabanlı Birlikte Çalışabilirlik Mühendisliği (MoBIE) adlı bir modelleme çerçevesi sunmuşlardır. Sundukları çalışma, farklı sistemlerin birlikte çalışmasına ve etkili bir şekilde bilgi alışverişinde bulunmasına yardımcı olmak için tasarlanmıştır. MoBIE'nin sistem merkezli modellerle entegrasyonuna izin verdiği belirtilmiştir. Ayrıca çalışma içerisinde, herhangi bir kavramsal modelleme dilinin kullanılabileceği de belirtilmiştir. Uygulama olarak ise, bir havaalanı terminalindeki yolcu kalkış sürecini analiz etmek için MoBIE'yi uygulamışlardır. Ortaya çıkan model, sistemler düzeyinde mimari ve operasyonel karar verme ve analiz olanağı sağlamaktadır [2].

Waseem ve Sadiq, uydu tasarımıda geliştirilen projelerde MBSE yaklaşımının kullanımını araştırmışlardır. Yazarlar, bilgi aktarımını kolaylaştırmak için NSS-1 adlı bir model deposu geliştirdiklerinden bahsetmişlerdir. Yaptıkları araştırma, gelişmiş tutarlılık, iyi yapılandırılmış modeller ve yapı ile davranış arasında net ayrım da dahil olmak üzere MBSE'yi Sistem Modelleme Dili (SysML) ile kullanmanın faydalarını vurgulamaktadır. SysML modeli ve diyagramlarının ayrıca eksik tasarım bilgilerinin belirlenmesine yardımcı olabileceği ve belirli bir tasarım ögesiyle ilgili bilgileri bulmayı kolaylaştırabileceği belirtilmiştir. Ayrıca, MBSE yaklaşımının izlenebilirlik, tasarım doğrulaması ve sistem davranış simülasyonu yoluyla otomatik sistem mühendisliğinin önünü açtığından da bahsedilmektedir [3].

Kaslow vd., görevlerde yüksek başarısızlık oranına sahip küçük uydular olan CubeSats'ın davranışlarını tanımlamak için sekiz adımlı bir yaklaşım sunmuşlardır. Yaklaşım, görev gereksinimleriyle başlamak ve SysML kullanılarak modellenen işlevsel bir mimariyle bitmektedir. Çalışmalarında, gelişmiş iletişim, azaltılmış risk, iyileştirilmiş kalite ve gelişmiş bilgi aktarımı gibi faydalar sağlayan MBSE yaklaşımının önemi vurgulanmaktadır. Araştırmaları, MBSE yaklaşımının bir CubeSat geliştirmesi esas alınarak örnekler sunmaktadır. Örnekler, görev verilerini toplama ve dağıtma gereksinimlerine odaklanmakta ve bu gereksinimleri karşılamak için gereken sistem işlevselliğine vurgu yapmaktadır [4].

Fei vd., havacılık ile ilgili sistemlerin geliştirilmesi için bir MBSE metodolojisi önermiştir. Metodoloji, mühendislerin ve geliştiricilerin karmaşık havacılık sistemlerini tasarlama ve geliştirmede karşılaştıkları zorlukları ele almayı amaçlamaktadır. Çalışmalarında, özellikle karmaşıklıklardan dolayı genel ihtiyaçların ilgili gereksinimler veya sistem öğeleriyle takip edilmesinin ve uygun sistem tasarım alternatifleri belirlenmesinin zorluğu vurgulanmaktadır. Çalışmaları, sistemlerin geliştirilmesi için göreve ve sisteme özgü tasarımın yürütülmesine yönelik yapılandırılmış bir yaklaşım sağlamaktadır. Yapılan çalışmada, sistem tasarımı için basitleştirilmiş bir MBSE projesi oluşturmaya yönelik faaliyetler tanımlanmıştır [5].

Bajaj vd., yeni nesil karmaşık sistemlerin oluşturulabilmesinde kolaylık sağlanması için Sistemlerin Yaşam Döngüsü Yönetimi (SLIM) adlı ve model tabanlı bir sistem mühendisliği çalışma alanının geliştirilmesi üzerine çalışmalar yapmışlardır. SLIM, sistemin kavramsal olarak soyutlanmasını temsil etmek için SysML'yi kullanmakta ve sürekliliğini sağlamaktadır. Çalışmada, sunulan SLIM araçlarının iki farklı türde olduğu

belirtilmiştir. Bunlar, SysML tabanlı analiz araçları ve SysML tabanlı entegrasyon araçlarıdır. İlki, sistem mühendislerinin sistem geliştirmeyi doğrudan SysML modelinden yönetmesine izin verirken, ikincisi ise ilgili disipline özel modelleri SysML'ye entegre etmek için çeşitli yöntemler ve arayüzler sağlamaktadır [6].

Estefan, günümüzde kullanılan ve önde gelen MBSE metodolojilerinin özet bir açıklamasını sunmuştur. Çalışma, bir bakıma metodoloji, ilgili süreçler, yöntemler ve araçların bir koleksiyonu olarak da tanımlanabilir. Yapmış olduğu çalışmada, MBSE metodolojisinden, sistem mühendisliği disiplini "model tabanlı" veya "model odaklı" bir bağlamda desteklemek için kullanılan ilgili süreçlerin, yöntemlerin ve araçların bir topluluğu olarak bahsetmiştir. Çalışmada ayrıca, mevcut olan çeşitli MBSE metodolojileri hakkında bilgi verilmekte ve açık literatürde yayınlanan NASA Jet Propulsion Laboratory (JPL) tarafından geliştirilen kontrol ve durum tabanlı MBSE metodolojisi de tanıtılmaktadır [7].

Ramos vd. yaptıkları çalışmada büyük, karmaşık ve sistemlerin sistemlerini (SoS) oluşturabilmek için bu konu üzerinde çalışan herkesin aynı "dili" konuşması ve aynı "madde" üzerinde çalışması gerektiğini belirtmişlerdir. Bahsetmiş oldukları, "Maddenin" anlamı sistem modelidir ve bunlarla ilgili mekanizmaların standart, değişikliklere elverişli ve kullanıcı dostu modelleme dilleri tarafından desteklenmesi gerektiğini belirtmişlerdir. Ayrıca, MBSE yaklaşımının bu duruma öncelik ettiği ve sistem mühendisliği alanında bir standart uygulama olması beklendiği belirtilmektedir [8].

Nielsen vd mevcut sistemlerin sürekli artan karmaşıklığı ve maliyeti ile birlikte bu sistemlerde performans düşüklüğüne, verimlilik kaybına ve güvenlik risklerine dikkat çekmiş ve potansiyel hataların ve anormalliklerin mümkün olan en erken zamanda tespit edilmesi ve gerçek zamanlı hata toleranslı işlemlerin uygulanması gerektiğini belirtmişlerdir. Özellikle son 40 yılda, birçok mühendislik sisteminde hata teşhis ve hata toleranslı kontrol yöntemleri ve uygulamaları hakkında başarılı sonuçlar alındığı vurgulanarak model tabanlı yaklaşımların bu konudaki önemine değinilmiştir. Çalışma içerisinde, son on yılda rapor edilen sonuçlar özellikle dikkate alınarak, gerçek zamanlı hata teşhisi ve hata toleranslı kontrol konularına kapsamlı bir inceleme sunulması amaçlanmıştır [9].

Steurer vd. tasarım aşamasındaki İHA sistemlerinin güvenilirlik analizi için yeni bir yaklaşım önermişlerdir. Önerilen yaklaşım, hata süreçlerini etkileyen sistem tasarım özelliklerinin bir modeli olan Çift Grafik Hata Yayılım Modeli'ne (Dual-graph Error

Propagation Model - DEPM) dayanmaktadır. Çalışmalarında SysML profili ve SysML modelinden DEPM'ye dönüştürme algoritması tanıtılmış, algoritmanın özellikleri ve çalışma mantığı ile ilgili bilgiler verilmiştir. Yapılan çalışma, SysML profilini kullanarak bir İHA tasarlamayı, SysML modelini DEPM'ye dönüştürmeyi ve güvenilirlik özelliklerini değerlendirmeyi amaçlayan bir İHA vaka çalışması üzerinden gösterilmiştir [10].

Massey ve Gaeta, taktik İHA'lar tarafından üretilen gürültüyü anlamak için gürültü ölçüm faaliyetleri yürütmüştür. Gürültüyü statik yer ölçümleri, uçuş ölçümleri ve yankısız odada ölçümler yoluyla ölçmüşlerdir. Uçuş ölçümleri için gürültü verileri, bir saniyelik aralıklarla spektrumlar oluşturularak analiz edilmiştir. Gürültü frekansında Doppler kaymaları gözlemlenmiştir. Tüm Ses Gücü Seviyesi (OASPL) her aralık için hesaplanmış ve farklı irtifalardaki üst geçitler için zamanın bir fonksiyonu olarak çizilmiştir. Öte yandan üst geçiş gürültüsü verileri, farklı hızlarda pistten yukarı ve aşağı geçişler ve üç farklı irtifada sabit yarıçaplı yörüngeler için toplanmıştır. Ölçümler sırasında İHA'nın konumu Küresel Konumlandır Sistemi (GPS) ile kaydedilmiştir. Pervane gürültüsü ve motor egzoz gürültüsünün tipik İHA'lar için eşit derecede önemli olduğunu tespit etmişlerdir. Ayrıca, üst geçiş gürültüsünün ölçülmesindeki zorlukları ve arka plan gürültüsüne gömülü gürültünün çıkarılmasına yönelik yöntemleri tartışmışlardır [11].

Papa vd., uçuş operasyonları sırasında küçük insansız hava aracı sistemlerinin (UAS) akustik emisyonlarını değerlendirmiştir. Syma X5C ve RC Eye One Xtreme olarak iki farklı küçük quad-copter modelinin ses gücü seviyesini (SWL) ve ses basıncı seviyesini (SPL) analiz etmişlerdir. Ölçümler EN ISO 3745 ölçüm yöntemi kullanılarak yankısız bir odada gerçekleştirilmiştir. Sonuçlar, UAS tarafından yayılan ses gücü seviyesinin motor gücüyle birlikte arttığını göstermiştir. SWL ve SPL üzerine yapılan araştırma ile ses gücü seviyelerinin kullanılmasının UAS'lerin yerini tespit etmek için bir sistem geliştirmek için faydalı olacağını ortaya koymuşlardır [12].

Pechan ve Sescu, farklı yüzey kusurlarına sahip pervanelerden yayılan gürültüyü değerlendirmek için deneysel akustik ölçümler gerçekleştirmiştir. Olumsuz koşullarda çalışan pervanelerin yaydığı gürültü imzasını anlamayı ve yüzey kusurlarının gürültü seviyeleri üzerindeki etkisini değerlendirmeyi amaçlamışlardır. Düzensiz çıkıntılar, çentikli kanat ucu, çentikli ön kenar, çentikli arka kenar ve girinti tipi pürüzlülük dahil olmak üzere çeşitli yüzey kusurları analiz edilmiştir. Belirli yüzey kusurlarının farklı

dönüş hızlarında genel gürültü seviyesini hafifçe artırabildiğini veya azaltabildiğini vurgulamışlardır [13].

Sinibaldi ve Marino, İHA'lar için pervanelerin aeroakustik özellikleri üzerine deneysel bir analiz gerçekleştirmiştir. Fırçasız elektrik motorları ile tahrik edilen optimize edilmiş ve geleneksel pervanelerin akustik izlerini karşılaştırmaya odaklanmışlardır. Ayrıca Ffowcs-Williams/Hawking denklemine ve geniş bant gürültüsü için basit bir modele dayanan sayısal bir analiz sunmuşlar ve tartışmışlardır. Deneysel analiz sonucunda, optimize edilmiş pervane tasarımının, geleneksel pervaneye kıyasla daha iyi bir akustik davranış sergilediğini ortaya koymuşlardır [14].

Leslie vd., düşük Reynolds sayılarında çalışan küçük boyutlu bir pervane için geniş bant gürültüsünü azaltma tekniğini incelemiştir. Ön-kenar sınır katmanında oluşturulacak yapının, hafif yük koşullarında geniş bant gürültüsünde büyük bir azalma sağladığı ve performansa zarar vermediği görülmüştür. Teknik, pervane profilinin emme yüzeyindeki laminer ayırma kabarcığını ortadan kaldırmak için çeşitli yükseklik ve uzunluklarda düz bir geçiş şeridinin kullanılmasını içermektedir. Ön rüzgar tüneli testleri, firar kenarı sınır tabakası yer değiştirme kalınlığındaki azalmanın, türbülanslı sınır tabakası firar kenarı gürültüsünde bir azalmaya neden olduğunu göstermiştir. Kullanılan teknik ile birlikte, statik testlerde SWL'de 4dB'ye kadar genel bir azalma sağlanmış ve 1kHz'in üzerindeki frekanslarda da benzer azalmalar elde edilmiştir [15].

Miljković, dronlar gibi İHA'lar tarafından üretilen gürültüyü azaltmak için çeşitli yöntemler önermiştir. Gürültü azaltımı için hem pasif hem de aktif çözümleri tartışmıştır. Pasif yöntemler arasında pistonlu motor susturucuları, Q uçlu pervaneler, daha fazla pervane kanadı, emici ve yansıtıcı bariyerler, kanallı pervaneler ve ses emici kanalların kullanımı yer almaktadır. Aktif çözümler için ise, gürültüyü azaltmak için tüm pervanelerin devir ve fazını eşleştiren bir cihaz olan senkrofaserin uygulanmasını içermektedir [16].

Ciaburro vd., akustik ölçümler kullanarak kapalı ortamlarda küçük İHA'ların varlığını tespit etmek için bir metodoloji geliştirmiştir. Geniş bir ortamda bir İHA tarafından yayılan gürültünün akustik ölçümlerini yapmışlar ve kanatların dönüşü nedeniyle 5000 Hz frekansında gerçekleşen tonal bir bileşeni vurgulamışlardır. Ayrıca ortama harici bir gürültü de eklemişler ve 5000 Hz'deki İHA gürültüsünün tonal bileşeninin hala ayırt edilebilir olduğunu bulmuşlardır. Bunun sonucunda, basit akustik

ölçümlerin ve frekans analizinin belirli bir kapalı ortamda İHA'ların varlığını saptayabileceği sonucuna varmışlardır [17].

Al-Emadi vd., akustik tabanlı drone tespiti ve tanımlaması için derin öğrenme tabanlı bir yöntem geliştirmiştir. İHA'ların benzersiz akustik parmak izlerinden yararlanmak ve onları tespit edip tanımlamak için Evrişimsel Sinir Ağı (CNN), Tekrarlayan Sinir Ağı (RNN) ve Evrişimsel Tekrarlayan Sinir Ağı (CRNN) algoritmalarını kullanmışlardır. Yazarlar, drone faaliyetlerinin ses kayıt örneklerini içeren veri kümelerini kullanarak bu sinir ağlarının performansını karşılaştırmıştır. Çalışmalarının lüteratüre en büyük katkısı, bu metodolojilerin gerçek hayat senaryolarında kullanımını doğrulamak ve drone tespiti ve tanımlaması için farklı derin sinir ağı(DNN) algoritmaları arasındaki performansın sağlam bir karşılaştırmasını sağlamaktır. Farklı algoritmaları doğruluk, F1 puanı, kesinlik, geri çağırma metrikleri, modellerin eğitimi ve test edilmesi için gereken hesaplama süresine göre değerlendirmiş ve karşılaştırmışlardır [18].

Altınors vd., İHA motorlarında arıza tespiti için ses tabanlı bir yöntem geliştirmiştir. İHA motorlarında pervane, eksantrik ve rulman arızaları oluşturmuşlar ve önerdikleri yöntemi motorlardan alınan ses verileri üzerinde uygulamışlardır. Elde edilen ses veri setine sinyal ön işleme, özellik çıkarma ve makine öğrenmesi yöntemleri uygulanmıştır. Makine öğrenmesi için Karar Ağacı (DT), Destek Vektör Makineleri (SVM) ve K-En Yakın Komşu (KNN) algoritmaları kullanılmıştır. Önerilen yöntem, DT, SVM ve KNN algoritmaları için sırasıyla %99,16, %99,75 ve %99,75 doğruluk oranları ile arıza teşhisinde yüksek doğruluk elde etmiştir. Çalışma, İHA motorlarında arıza tespiti alanına katkı sağlamakta ve gömülü sistemlerde gerçek zamanlı çalışma avantajı sunmaktadır [19].

Glowacz, akustik sinyaller kullanarak üç fazlı bir indüksiyon motoru için arıza teşhis teknikleri geliştirmiştir. Analiz ettiği teknikler, kırık rotor çubuğu gibi durumlara dayalı olarak motorun dört gerçek durumunu içermektedir. Akustik sinyallerin tanınması için KNN, geri yayımlı sinir ağı ve kelime kodlamasına dayalı sınıflandırıcı kullanılmıştır. Tanıma sonuçlarının gerçek veriler için tatmin edici olması, akustik sinyallere dayalı olarak geliştirilen arıza teşhis tekniklerinin etkinliğini göstermektedir [20].

Krishnasarma vd., elektrik motorlarının akustik imzasını analiz etmiş ve algılanan genel sese katkıda bulunanları belirlemek için motorun yapısal tepkisini akustik

spektrumuyla ilişkilendirmişlerdir. Genel sesi azaltmak için fan gürültüsü ve rulman arızalarını gidermek gibi teknikler önermişlerdir. Ayrıca, motorun titreşim modelini ve rezonanslarını anlamak için deneysel modal analiz (EMA) ve operasyonel modal analiz (OMA) kullanımını tartışmışlardır. Yapısal titreşimler için bir iletim yolu olarak yük yataklarının önemini vurgulamışlar ve dinamik elektromanyetik kuvvetler tarafından oluşturulan rezonansları tanımlamışlardır. Çalışmaları, fan kanadı geçiş frekansı gibi tonal frekansların varlığını ve bunların yapısal rezonanslarla etkileşimini vurgulamaktadır. Fan gürültüsünü azaltmanın ve yatak arızalarını gidermenin, oluşan sesi etkili bir şekilde azaltabileceğini öne sürmüşlerdir [21].

Iannace vd., akustik ölçümleri kullanarak kapalı ortamlardaki İHA'ları tespit etmek için bir lojistik regresyon modeli geliştirmiştir. Gerçek dünya koşullarını simüle etmek için bir alışveriş merkezindeki sesleri kaydetmişler ve bu sesleri kapalı bir ortamda yeniden üretmişlerdir. Yazarlar, İHA ve İHA olmayan durumları ayırt etmek için 50 Hz-6,3 kHz frekans aralığındaki 13 oktav banttaki ortalama spektrumdan özellikler çıkarmışlardır. Özellikleri ölçeklendirmek için Min-Max normalizasyonunu kullanmışlar ve etiketli verileri kullanarak lojistik regresyon modelini eğitmişlerdir. Model 0,994 (%99.4) gibi yüksek bir doğruluk oranına ulaşarak çok sayıda doğru tespit yapıldığını göstermiştir [22].

Bondyra vd., işlem gücü kısıtlı bir bilgisayar üzerinde bulunan bir mikrofon ile kaydedilen akustik emisyonun analizini kullanarak döner kanatlı İHA'ların kırık kanatlarını tanımak ve tanımlamak için bir teşhis sistemi geliştirmiştir. Sistem, akustik sinyallerin karakteristik özelliklerini, özellikle de Mel Frekans Spektrum Katsayılarını sınıflandırmak için yapay bir sinir ağından yararlanan veri odaklı bir yaklaşım kullanmaktadır. Modelin parametrelerinin kapsamlı bir değerlendirmesini yapmışlar ve sadece arıza oluşumunu tespit etmekle kalmayıp aynı zamanda mikrofon ile sağlanan çok kanallı verileri kullanarak bozulmuş rotorun konumunu da bildiren son derece hassas bir arıza sınıflandırıcı geliştirmişlerdir. Önerilen yöntem, kırık rotor blade arızalarını tespit etmede ve farklı bozulma türlerini ayırt etmede %98'i aşan bir doğruluk elde etmiştir [23].

Liu vd., İHA'nın uçuşundan kaynaklanan ses gürültüsüne dayalı olarak quad-rotor İHA'larda pervane hasarını tespit etmek için bir yöntem geliştirmiştir. Bir hata teşhis modeli geliştirmek için CNN ve transfer öğrenme teknikleri kullanmışlardır. İHA'lardan gerçek zamanlı olarak toplanan ses verileri zaman-frekans spektrogramlarına dönüştürülmüş ve CNN tabanlı teşhis modelini eğitmek için kullanılmıştır. Model,

spektrogramdaki anormal özellikleri tespit edebilmiş ve pervanelerdeki fiziksel hasarı belirleyebilmiştir. Transfer öğrenme, İHA'nın dinamik modellerine veri bağımlılığını azaltmak ve farklı dinamik modellere sahip İHA'lardan model verilerinin kullanılmasını sağlamak için kullanılmıştır. Testler sonucunda, önerilen modelin %90'ın üzerinde bir doğruluk sağladığı belirlenmiştir [24].

Magdaleno vd., kalkış ve havada asılı kalma sırasında elde edilen ses sinyallerini kullanarak bir quadrotor İHA üzerindeki dengesiz kanatları tespit etmek için bir metodoloji önermiştir. Metodoloji, İHA'nın uçuşu sırasında ses sinyallerinin kaydedilmesini ve analiz edilmesini içermektedir ve sonuçlar, dengeli ve dengesiz kanatları ayırt etme yeteneğini göstermektedir. Sinyaller Ayırık Dalgacık Dönüşümü (DWT) ayrıştırması ve Fourier dönüşümü kullanılarak analiz edilmiş ve sonuçlar önerilen metodolojinin dengeli ve dengesiz kanatları ayırt edebildiğini göstermiştir [25].

Katta vd., yaptıkları çalışmada İHA'daki pervane anomalilerinin gerçek dünya ses veri kümesini sunmuş ve pervane hasarının sınıflandırılması için derin öğrenme modellerini kullanmışlardır. Veri kümesi, bir İHA quad-copterindeki sağlam ve kırık pervanelerin çeşitli konfigürasyonlarını kapsayan beş saatten fazla ses kaydından oluşmaktadır. Kayıtlar, otonom iç mekan görevleri sırasında İHA'ya monte edilmiş bir mikrofon kullanılarak elde edilmiştir. Sonrasında, DNN, CNN, Uzun Kısa Süreli Bellek (LSTM) ve Dönüştürücü Kodlayıcı (TrEnc) gibi farklı derin öğrenme mimarilerini karşılaştırmışlardır. Çalışma sonucunda, TrEnc mimarisinin %98,30 doğruluk, 0,98 kesinlik ve 0,98 geri çağırma ile diğerlerinden daha iyi performans gösterdiğini bulmuşlardır [26].

Glowacz vd., akustik sinyaller kullanarak tek fazlı asenkron motorlar için bir erken arıza teşhis tekniği geliştirmiştir. Sağlıklı bir motor, arızalı rulmanlara sahip bir motor ve arızalı rulmanlara ve yardımcı sargının kısa devre bobinlerine sahip bir motor dahil olmak üzere motorun durumlarını ölçmüş ve analiz etmişlerdir. Akustik sinyallerden özellik vektörleri oluşturmak için MSAF-20-MULTIEXPANDED adlı bir özellik çıkarma yöntemi kullanmışlardır. Elde edilen vektörler KNN, En Yakın Ortalama (NM) ve Gauss Karışım Modeli (GMM) sınıflandırıcıları kullanılarak sınıflandırılmıştır. Önerilen tekniğin, tek fazlı asenkron motorların yanı sıra diğer dönen elektrik motoru türlerinin teşhisi için de kullanılabileceğini belirtmişlerdir [27].

Radonjic vd., dönen motorların durum tespiti için yeni bir akustik tabanlı Nesnelerin İnterneti (IoT) sistemi önermiştir. Sistem, mobil ve ucuz bir IoT cihazından

ve Döner Makinelerin Arıza ve Durum Tespiti (FASTER) adlı bir algoritmadan oluşmaktadır. Algoritma, döner makinelerin karakteristik akustik sinyallerinden faydalı bilgiler çıkarmak için DWT ve basit sinir ağlarını birleştirmektedir. Algoritmanın hiperparametreleri bir genetik algoritma kullanılarak ayarlanmıştır. Sistem, güçlü akustik kirliliğe sahip gerçek bir endüstriyel ortamda test edilmiş ve sonuçlar, yaklaşık 0,99(%99) ortalama F1 puanı ile yüksek doğruluk göstermiştir [28].

Kemalkar ve Bairagi, ses analizi kullanarak motorlar için bir arıza teşhis yöntemi geliştirmiştir. Bir bisiklet motorunun akustiğinden sensör sinyalleri toplamışlar ve Mel-Frekans Cepstral Katsayıları (MFCC) algoritmalarını kullanarak bir özellik kümesi çıkarmışlardır. Arıza ve arıza olmayan durumlar, arıza ve arıza olmayan özellik profilleri ile karşılaştırılarak belirlenmiştir. Yazarlar, ses analizi kullanarak arıza teşhisi için MFCC algoritmasını kullanmışlardır [29].

Iannace vd. İHA pervanelerindeki dengesiz kanatları tespit etmek için yapay sinir ağı (ANN) algoritmalarını kullanan bir sınıflandırma modeli geliştirmiştir. Model, kanada uygulanan kağıt bant şeritlerinin neden olduğu aerodinamik modifikasyonu tanımlamak için kullanılan İHA tarafından yayılan gürültünün ölçümlerine dayanarak oluşturulmuştur. Model, dengesiz kanatların tespitinde yüksek doğruluk (0.9763 – %97.63) göstererek çok sayıda doğru tespit yapmıştır. Yazarlar, özellikle uçuştan önce bir İHA'nın çalışma koşullarını doğrulamak için bu modelin kullanılabileceğini belirtmiştir. Çalışma ayrıca, pervane kusurlarının hava aracının düşmesine neden olabileceği ve etki alanındaki nesneler ve insanlar için risk oluşturabileceği için güvenlik üzerindeki etkilerini de vurgulamaktadır [30].

Ji vd. akustik sinyal işleme kullanarak akıllı arıza teşhisi için Paralel Seyrek Filtreleme (PSF) adı verilen yeni bir arıza teşhis yöntemi önermiştir. Yöntem, gürültülü ortamlarda akustik sinyallerden önemli özellikleri doğru bir şekilde çıkarmayı amaçlamaktadır. PSF, seyrek filtrelemeye dayalı başka bir normalleştirme özelliği ekleyerek seyrek özellik çıkarımı sağlamakta ve bu da arıza sınıflandırması için daha seyrek ve daha verimli özellikler elde edilmesini sağlamaktadır. Önerilen yöntem simülasyon ve deneysel veriler kullanılarak test edilmiş ve akustik sinyaller altında mekanik arıza teşhisinde başarı göstermiştir [31].

Kołodziejczak vd. İHA rotorları için daha önce geliştirilen bir hata tespit ve tanımlama (FDI) şemasında iki iyileştirme önermişleridir. İlk iyileştirme, sinir ağlarının boyutunu ve hesaplama yükünü azaltan özellik uzayının azaltılması için Temel Bileşen

Analizinin (PCA) kullanılmasıdır. İkinci iyileştirme, sistemin nihai durumunu sağlayan bir karar füzyon stratejisi ile çoklu zayıf sınıflandırıcılardan oluşan bir topluluğun tanıtılmasıdır. Önerilen iyileştirmeler gerçek uçuş akustik verileri kullanılarak değerlendirilmiş ve performans kısıtlamalarını korurken hesaplama süresini önemli ölçüde azalttığı görülmüştür. Ayrıca, mikrofon kanallarına atanan farklı ağırlıkların etkisi ve hata sınıflarının sınıflandırma doğruluğu için bir parametrenin nasıl ayarlanması gerektiği de tartışılmıştır [32].

Gomez vd., akustik kullanarak İHA'lardaki hasarlı veya dengesiz pervaneleri tespit etmek için tahribatsız bir test yöntemi önermiştir. Tek bir pervane için tasarlanmış bir prototipe dayalı olarak arıza teşhisi için sinir ağı mimarisine sahip bir makine öğrenimi algoritması sunmuşlardır. Yazarlar, veri kayıt prosedürlerinin ve ekipman kurulumlarının başarılı teşhis üzerindeki etkisini araştırmış ve ilgili zaman ve frekans alanı özelliklerini tanımlamıştır. Elde edilen sonuçları, İHA'lar için iki mikrofondan oluşan bir akustik izleme sisteminin uygulanmasına yönelik kurallar türetmek için kullanmışlardır [33].

Yang vd., küçük hasarlı quadrotor pervaneleri için akıllı bir arıza teşhis algoritması olan 1D-WIDRSN'yi geliştirmişlerdir. Algoritma, ek arındırma prosedürleri olmadan girişim bilgisi altında İHA'nın arıza sınıflarını etkili bir şekilde tanımlamaktadır. Uçuş verilerine dayanarak erken küçük arızaları tespit ve teşhis ederek ciddi arızalar meydana gelmeden önce onarım yapılmasına olanak tanımakta ve böylece quadrotorun hizmet ömrünü uzatmaktadır. Algoritmada, örnek sayısını genişletmek için kayan pencere(Sliding Window) yöntemi kullanılmış ve sinyal özelliklerindeki gürültüyü ortadan kaldırmak için yeni bir aşamalı yarı yumuşak eşik(Semi-Soft Threshold) sunulmuştur. Ek olarak, algoritmanın gürültü önleme ve over-fiting yeteneğini geliştirmek için geniş bir konvolüsyon katmanı ve DropBlock yöntemi kullanmışlardır. Test sonuçları, 1D-WIDRSN'nin parazit bilgilerinin varlığında arıza kategorilerini belirlemede %98'in üzerinde doğruluk elde ettiğini göstermektedir [34].

Pourpanah vd., İHA motorları ve pervanelerindeki arızaların erken tespiti için bir izleme sistemi geliştirmiştir. Stator akım sinyallerini analiz etmek için Motor Akım İmza Analizi (MCSA) ve motorların çalışma durumunu değerlendirmek için Bulanık Adaptif Rezonans Teorisi (ART) sinir ağını kullanmışlardır. Pervaneleri izlemek için Titreşim İmza Analizi (VSA) tekniği kullanılmış ve istatistiksel özellikleri öğrenmek için Q-öğrenme tabanlı Bulanık ARTMAP Sinir Ağı kullanılmıştır. Özellik seçimi için Genetik algoritma (GA) kullanılmıştır. Önerilen modelin, Sınıflandırma ve Regresyon Ağacı

(CART), KNN, Naive Bayes ve SVM gibi diğer yöntemlere kıyasla arızaları tespit etmede daha etkili olduğu belirtilmiştir [35].

Benini vd., yüksek hızlı atalet ölçüm biriminden (IMU) gelen ivme sinyallerini kullanarak Dikey Kalkış ve İniş (VTOL) yapabilen İHA'lar için bir aktüatör arıza tespit algoritması geliştirmiştir. Algoritma, ivme sinyallerinin zaman ve frekans alanı analizine ve arızanın meydana gelmesiyle ilişkili ilgili frekanslara ve zaman alanı özelliklerini belirlemek için özellik seçim tekniklerine dayanmaktadır. Algoritma, Songbird VTOL İHA'dan elde edilen gerçek veriler üzerinde, özellikle dikey kalkış ve iniş sırasında bir pervane blade'inin hasarına odaklanarak test edilmiştir. Test sonuçları, VTOL İHA'larda teşhis amacıyla ivme sinyallerinin kullanılmasının etkisini ortaya koymuştur [36].

Bondyra vd., sinyal işleme ve makine öğrenimi tekniklerini kullanarak İHA rotor blade'lerinin arıza tespiti ve durum izlemesi için üç aşamalı bir algoritma geliştirmiştir. Yöntem, yerleşik IMU sensöründen alınan ve döngüsel bir buffer'da depolanan ve arızalı durumun karakteristik bir imzasını elde etmek için özellik çıkarma algoritmaları kullanılarak işlenen ivme ölçümlerine dayanmaktadır. Hızlı Fourier Dönüşümü (FFT), Dalgacık Paket Ayırıştırması (WPD) ve doğrusal aralıklı frekans bantlarında sinyal gücünün ölçülmesi dahil olmak üzere üç farklı özellik çıkarma yöntemi dikkate alınmıştır. SVM sınıflandırıcısı daha sonrasında rotor arızasının oluşumunu, ölçeğini ve türünü belirlemek için kullanılmıştır. Önerilen çözümün etkinliği bir dizi test ile doğrulanmıştır [37].

Yang vd., dört rotorlu bir İHA'nın pervane hasarı için "Stacked Pruning Sparse Denoising Autoencoder and Convolutional Neural Network" (sPSDAE-CNN) kullanarak akıllı bir arıza teşhis yöntemi önermiştir. Veri iyileştirme için tek boyutlu bir kayan pencere sunmuşlar ve modellerin derin öğrenme yeteneğini geliştirmek için zaman alanı verilerini iki boyutlu gri görüntülere dönüştürmüşlerdir. sPSDAE-CNN modeli, İHA pervane hasarı için geleneksel evrişimli sinir ağlarına kıyasla daha iyi kararlılık ve güvenilir tahmin doğruluğu göstermiştir. Ayrıca, -4 dB'lik bir sinyal-gürültü oranında bile %90'lık bir doğruluk oranına ulaşarak yüksek gürültülü ortamlarda iyi bir teşhis doğruluğu göstermiştir. sPSDAE ve CNN kombinasyonunun, arıza teşhis modelinin doğruluğunu ve genelleme yeteneğini geliştirmede etkili olduğu belirtilmiştir [38].

Ghulamchi ve Mueller, hava aracına yerleştirilmiş bir ivmeölçerden elde edilen titreşim spektrumunu kullanarak multikopter pervanelerindeki arızaları teşhis etmek için titreşim tabanlı bir yöntem geliştirmiştir. Yöntem, motorların farklı manevralar sırasında

farklı hızlarda dönmesi gerçeğinden yararlanarak hasarlı pervaneleri izole etmek için ölçülen titreşimlerin spektral analizine odaklanmaktadır. Geliştirme sonucunda, yöntemin hem tekli hem de çoklu hasarlı pervanelerin belirlenmesindeki başarısı gösterilmiştir. Önerilen algoritma yerleşik bir ivmeölçer kullanmakta ve bu sayede çok çeşitli multikopterlere uygulanabilmektedir. Önerilen konseptin doğruluğunu göstermek için deneysel sonuçlar da sunulmuştur [39].

Al-Haddad ve Jaber, çok çözünürlüklü dönüşüm özelliklerine dayalı bir DNN kullanarak çok motorlu İHA'lar için akıllı bir arıza teşhis yaklaşımı önermiştir. Çalışmada, hasarlı pervanelere sahip ve havada asılı duran bir quad-copter'den ivmeölçer kullanılarak geniş ölçekli, yüksek kaliteli ve kapsamlı veriler elde edilmiştir. Arıza teşhisinde çift yönlü öngörülemezliği telafi etmek için hibrit tabanlı dönüştürülmüş bir ayırık dalgacık ve çok katmanlı bir DNN şeması kullanmışlardır. Önerilen yaklaşım %91'lik bir sınıflandırma doğruluğuna ulaşmış ve mevcut son teknoloji arıza teşhis stratejilerini geride bırakmıştır. Yazarlar ayrıca üç eksenli durağan olmayan altı seviyeli çok çözünürlüklü analizin istatistiksel özelliklerini araştırmış ve sınıflandırma doğruluğunu artırmak ve hesaplama süresini en aza indirmek için özellik seçim yöntemlerini çalışmada belirtmişlerdir [40].

Palanisamy vd., elektrikli İHA'larda pervane blade performansını ve hasarını tespit etmek için genişletilmiş bir Kalman filtresi tabanlı parametre tahmin algoritması geliştirmiştir. Çalışmada pervanenin aerodinamik verimliliğine odaklanmışlar ve bunu arıza tespiti için bir güç aktarma organı modeline dahil etmişlerdir. Önerilen tekniğin sayısal simülasyonlar aracılığıyla başarılı sonuçlar verdiğini ortaya koymuşlardır. Ayrıca, herhangi bir hasar senaryosunda en sık etkilenen parametre olması nedeniyle pervane hasarını belirlemek için tork parametresinin izlenmesinin önemini de çalışmada vurgulamışlardır [41].

Tong vd., quadrotor İHA'larda arıza tespiti ve değerlendirmesi için hava aracı üzerinde veri odaklı bir sistem geliştirmişlerdir. Normal ve arıza koşulları altında uçuş veri kümeleri oluşturmak için veri odaklı modelleri ve dinamik modelleri birleştiren hibrit bir veri oluşturma modeli önermişlerdir. Arızalı bir pervanenin performansındaki düşüşü temsil etmek için bir LSTM ağı kullanmışlardır. Pervanedeki hasarın derecesini belirlemek ve değerlendirmek için CNN'e dayalı bir arıza sınıflandırıcı önermişlerdir. Bu yaklaşımı gerçek uçuş testleri ile test etmişler ve test setinde %80'in üzerinde bir teşhis doğruluğu elde etmişlerdir. Ayrıca, quad-rotorlarda ortalanmamış CG'nin (Ağırlık

Merkezi) hesaba katılmasının önemini vurgulamışlar ve bu sorunu ele almak için mantıklı bir yaklaşım önermişlerdir. Çalışma, Dakikadaki Devir Sayısı (RPM) değerlerini ve durum değişkenlerini girdi olarak kullanarak hatalı pervanelerin yerini belirlemede ilgili yaklaşımın etkili olduğunu göstermiş ve gerçek dünyadan toplanan veriler üzerinde %76,32'ye varan bir doğruluk elde etmiştir [42].

Ma vd., derin öğrenmeye dayalı titreşim verisi toplama ve işleme teknolojilerini kullanarak İHA hasar tespiti ve tanımlaması için yeni bir yöntem sunmuşlardır. Bir titreşim sensörü ve buna bağlı sinyallerdeki yüksek frekanslı gürültüyü azaltmak için ampirik mod ayrıştırması (EMD) kullanılmış ve Y eksen ivme verilerini belirlemek için ortalama karekök hatası (RMSE) özelliği kullanılmıştır. Titreşim verilerine dayanarak hasarı tanımlamak için bir CNN kullanılmış ve seçilen ve gürültüsü azaltılmış Y eksen ivme verileri kullanılarak %97,5 doğruluk elde edilmiştir [43].

Zhang vd., İHA arıza teşhisi için fark tabanlı derin evrişimli sinir ağı (DD-CNN) modeli geliştirmiştir. Model, simüle edilmiş verilerle eğitilen sınıflandırıcılar ile gerçek uçuşlar arasındaki performans farkını gidermeyi amaçlamaktadır. Daha sonrasında, simülasyondan gerçeğe farkı azaltmak için kullanılan fark özelliklerini çıkarmak için DCNN kullanmışlardır. Ayrıca, gerçek uçuş verilerinin dağılımını simülasyon verilerinin dağılımına yaklaştırmak için bir alan uyarlama yöntemi önermişlerdir. Test sonuçları, önerilen yaklaşımın gerçek uçuşta pervane arızalarını tespit etmede %97,9'luk bir doğruluk elde ettiğini göstermiştir [44].

Cabahug ve Eslamiat, K-ortalamlar kümeleme(K-Means Cluster) algoritmasını kullanarak İHA'lar için bir arıza tespit sistemi geliştirmiştir. Parrot ANAFI quad-copter'in uçuş sırasındaki titreşimini ölçmek için bir IMU sensör kullanmışlar ve sensör okumalarından titreşim grafikleri elde etmişlerdir. Ayrıca titreşim verilerini analiz etmek ve farklı sağlık durumlarını kümeler halinde sınıflandırmak için K-ortalamlar kümeleme algoritmasını kullanmışlardır. Amacın, her bir veri noktası ile en yakın merkez arasındaki Öklid mesafesini en aza indirmek olduğu belirtilmiştir. Sistem, arızalı İHA'lardaki arızaları tespit etmeyi ve kaza sayısını azaltmayı amaçlamıştır. Çalışmada, seçilen veri ve parametre setlerine dayalı olarak Quadcopter Arıza Tespit Kümeleri (QFDC) grafikleri ve karmaşıklık matrisleri (Confusion Matrix) elde edilmiştir [45].

Zhang vd., gerçek verileri kullanarak quad-rotor pervanelerinin sağlık durumunu izlemek için bir yaklaşım önermişlerdir. Bir Derin Evrişimli Sinir Ağı (DCNN) modeli için eğitim verileri oluşturmak üzere ayarlanmış bir simülasyon modeli kullanmışlardır.

DCNN için girdiler pervane için hem girdi hem de çıktı bilgilerini içermek ve girdi ve çıktı bilgileri arasındaki ilişkinin karmaşıklığını en aza indirmek üzere iki ana kritere göre seçilmiştir. DCNN modeli, oluşturulan veri kümesi kullanılarak eğitilmiş ve ardından gerçek uçuş verileri üzerindeki arızaları sınıflandırmak için kullanılarak başarı elde edilmiştir [46].

Li vd., titreşim ölçümlü derin istatistiksel özellik öğrenimi kullanarak dönen makinelerde arıza teşhisi için bir model geliştirmiştir. Titreşim sensörü sinyallerini zaman, frekans ve zaman-frekans alanlarında temsil etmişler ve bunları istatistiksel bir özellik kümesi üretmek için kullanmışlardır. Yaklaşımlarında, gerçek değerli Gauss-Bernoulli kısıtlı Boltzmann makineleri (GRBM'ler), ve Gauss-Bernoulli derin Boltzmann makinesi (GDBM) kullanmışlardır. Önerilen yaklaşım hem dişli kutusu hem de rulman sistemlerine uygulanarak dişli kutusu için %95,17 ve rulman sistemi için %91,75 hata sınıflandırma performansları elde edilmiştir. Yaklaşım, SVM ve GRBM gibi standart yöntemlerle karşılaştırılmış ve önerilen model en iyi hata sınıflandırma oranına ulaşmıştır. Sonuçlar, arızaların teşhisi için istatistiksel özellik çıkarımı ile derin öğrenmenin potansiyelini ortaya koymuştur [47].

Başkaya ve Bronz, makine öğrenimi tekniklerini kullanarak küçük İHA'lar için bir arıza tespit ve teşhis yöntemi geliştirmiştir. İHA'ların emniyetli ve güvenilir bir şekilde çalışmasını sağlamak için hata tespiti ve teşhisinin önemini vurgulamışlardır. Hata tespiti ve hata teşhisinin iki ana adımını tartışarak, hatalara duyarlı ve model belirsizliklerine ve dış bozulmalara karşı dayanıklı yöntemlere duyulan ihtiyaçtan bahsedilmiştir. Çalışmada, arıza teşhisi için model tabanlı ve veri odaklı yaklaşımların bir kombinasyonu önerilmiş ve daha iyi çözümler elde etmek amaçlanmıştır. Ayrıca arıza sınıflandırması için SVM kullanımının, genelleme ve doğrusal olmayan sistemlerle başa çıkma açısından avantajları vurgulanmıştır. SVM yaklaşımının özellikle kontrol yüzeylerinin etkinlik kaybı konusunda önem arz ettiği belirtilmiştir [48].

Hu vd., İHA sensörleri için hibrit bir özellik modeli ve derin öğrenme tabanlı arıza teşhis yaklaşımı önermiştir. GPS, IMU ve Hava Veri Sistemi (ADS) dahil olmak üzere farklı sensör arızalarından artık sinyalleri toplamışlardır. Artık sinyaller Kısa Zamanlı Fourier Dönüşümü (STFT) kullanılarak zaman-frekans haritalarına dönüştürülmüştür. Daha sonra haritalardan özellikler çıkarmak ve İHA sensörleri için arıza teşhisi uygulamak için bir CNN kullanılmıştır. Metodolojinin performansı uçuş testleri ile değerlendirilmiş ve sonuçlar CNN'in sensör arıza bilgilerini başarılı bir şekilde

çıkarıldığını ve artıklar(Rezidüler) ile sensörlerin sağlık durumu arasında arıza teşhis mantığı oluşturduğunu göstermiştir [49].

Ghazali vd., dronlar için özellikle çoklu motor kollarına odaklanan titreşim tabanlı bir arıza tespit sistemi önermişlerdir. Gerçek zamanlı titreşim verilerine dayanarak çoklu motorun güvenliğini tahmin etmek için bulanık mantık, nöro-bulanık ve sinir ağı gibi AI tekniklerini bir araya getirmişlerdir. Çalışmada, bu AI yöntemlerinin performansı karşılaştırılmış ve bulanık mantığın istenen değere en yakın sonuçlar verdiği belirtilmiştir. Bununla birlikte, nöro-bulanık ve sinir ağı yöntemlerinin etkinliğinin dış ortamda daha iyi olabileceği vurgulanmıştır. Çalışma ayrıca gelecekteki araştırmalarda pervane titreşimi, motor durumu ve batarya seviyesi gibi diğer parametrelerin de dikkate alınabileceği belirtilmiştir. Çalışmada son olarak, renk kodlu bir sisteme dayalı olarak güvenli, kısmen güvenli veya güvensiz olup olmadığını gösteren çoklu motorun durumunu izlemek için kullanıcı arayüzü olarak bir mobil uygulama geliştirmiştir [50].

Saied vd., rotor arızalarına ilişkin koaksiyel bir okto-rotor için hata toleranslı bir yaklaşım sunmuşlardır. Önerilen mimari hata tespiti, hata izolasyonu ve sistem kurtarmayı içermektedir. Doğrusal olmayan bir gözlemci hata teşhisi için artıklar(residüler) üretmekte ve bir çıkarım modeli hatalı motoru değerlendirerek izole etmektedir. Daha sonra, arızalı motoru telafi etmek ve istikrarlı uçuşu sürdürmek için okto-rotorun yerleşik donanım yedekliliğini kullanan bir kurtarma algoritması geliştirmişlerdir. Yaklaşım gerçek uçuşlar üzerinde test edilmiştir. Çalışmada ayrıca, quad-rotorlar ve dörtten fazla rotora sahip çoklu rotorlar için hataya toleranslı kontrol stratejileri de tartışılmıştır [51].

Semke ve Dunlevy, İHA kullanıcıları arasında yaygın olarak kullanılmakta olan küçük boyutlu bir İHA'nın titreşim ortamı hakkında kapsamlı bir inceleme geliştirmişlerdir. Çalışmaları, hava araçlarındaki görüntüleme sistemlerinin performansını arttırmak için titreşim izolasyonu ve absorvasyon sistemlerinin düzgün bir şekilde tasarlanabilmesi için önemli verileri belirlemek üzerinedir. Araştırmacılar, titreşimleri ölçmek için bir ivmeölçer kullanarak hem çok rotorlu hem de sabit kanatlı İHA'lar da dahil olmak üzere havada asılı (Hover) veya düz uçuş (Level Flight) konfigürasyonundaki çeşitli hava araçlarının gövdelerinden veriler toplayarak titreşim seviyelerini ve frekanslarını anlamının önemini vurgulamışlardır. İstatistiksel ölçümler de dahil olmak üzere, araştırma bulguları titreşim kontrolü sistemlerinin geliştirilmesi önemli katkılar vermeyi hedeflemiştir [52].

Kumar vd., Sürdürülebilir Kentsel Hava Hareketliliğini (Urban Air Mobility) geliştirmek için çok rotorlu olan elektrikli VTOL tipi (eVTOL) hava araçları için bir aeroakustik titreşim analizi gerçekleştirmişlerdir. Bu sayede, bu tip hava araçlarındaki gürültüyü ve titreşimleri anlamaya ve azaltmaya odaklanmışlardır. Bunun için, 3 boyutlu bir yaklaşım kullanarak çeşitli uçuş aşamalarındaki titreşim ve akustik davranışları analiz etmişlerdir. İzleme ve analiz aşamaları için ivmeölçer, mikrofon ve takometreleri kullanmışlardır. Oluşturmuş oldukları gürültü spektrumu, 800Hz'e kadar olan düşük seviyelerde düşük frekansları ve 6-9Khz civarında ise daha yüksek frekansların ölçüldüğünü ortaya koymuştur. Titreşim analizi ise, 200 Hz'de baskın bir frekans varlığını saptamıştır. Bulgular sonucunda daha sessiz ve titreşimden doğabilecek sorunlara karşı daha dayanıklı eVTOL platformlarının geliştirilmesine katkıda bulunulmuştur [53].

Radkowski ve Szulim, manevralar sırasında quadcopterlerdeki titreşim durumlarını ve bu durumlar sonucunda oluşan sorunları analiz etmiştir. Montaj veya imalat hatasıyla ilgisi olmayan bu titreşimlerin motor ve pervane dengesizliklerinden kaynakladığını belirtmişlerdir. MATLAB/Simulink kullanarak, diğerlerine göre fazladan dönüşe maruz kalan bir rotoru modellemişler ve doğru parametre setinin bu tür titreşimleri ortadan kaldıracabileceğini göstermişlerdir. Çalışmaları fotoğrafçılık gibi yüksek stabilite gerektiren uygulamalar için titreşimleri en aza indirmenin önemini vurgulamakta ve İHA performansını ve güvenilirliğini artırmak için geliştirilmiş titreşim izolasyonu ve titreşimi ortadan kaldırma stratejilerine duyulan ihtiyacı vurgulamaktadır [54].

He vd., farklı pervane türlerinin etkilerine odaklanarak kalkış sırasında quadcopterlerde oluşan titreşimleri analiz etmişlerdir. Bilgisayar tabanlı bir sistem kullanarak İHA'lardaki titreşim seviyeleri üzerindeki etkilerini belirlemek için çeşitli pervanelerden veriler toplamış ve analiz etmişlerdir. Çalışmada, sıradan pervanelerin katlanır pervanelere göre daha az titreşime neden olduğunu ve daha uzun pervanelerin titreşime daha yatkın olduğunu ortaya koymuşlardır. Araştırmada, titreşimleri en aza indirmek ve bu sayede İHA'nın performansını ve stabilitesini artırmak için uygun pervane türlerinin seçilmesinin önemini vurgulanmaktadır [55].

Mizui vd., pervane dengesinin küçük ölçekli İHA'ların uçuş stabilitesi ve sensör doğruluğu üzerindeki etkilerini araştırmışlardır. Bunun için, rotor koşullarını simüle etmek amacıyla deneysel bir cihaz geliştirmişler ve dengeli ve dengesiz pervanelerin itme ve akım da dahil olmak üzere çeşitli parametreler üzerindeki etkilerini ölçmüşlerdir.

Çalışma, dengesiz pervanelerin önemli sayılacak miktarda merkezci ivme kuvveti ürettiği ve bunun da İHA'nın rotor kolunun doğal frekansı ile birleştiğinde artan titreşimlere ve rezonansa yol açtığını bulmuşlardır. Ayrıca bu rezonansın, uçuş stabilitesini tehlikeye atabilecek sensör okumalarını olumsuz yönde etkilediğinden de bahsetmişlerdir. Sonraki adımda, pervaneleri dengeleyerek merkezci ivme kuvvetinde bir azalma olduğunu ve böylece uçuş stabilitesinin ve sensör güvenilirliğinin arttığını göstermişlerdir. Çalışma, İHA performansının korunmasında pervane dengesinin kritik önemini vurgulamaktadır [56].

Simsiriwong ve Sullivan, kompozit bir İHA kanadı üzerinde deneysel bir titreşim analizi gerçekleştirmiştir. Kanadın modal özelliklerini kanatların asılı uçağa monte edildiği serbest bir düzenleme ve sarsıcı tabla üzerine dikey olarak monte edilmiş tek bir kanat olarak iki konfigürasyon kullanarak araştırmışlardır. Dinamik özellikleri yakalamak için ise çift eksenli bir ivmeölçerler kullanmışlardır. Çalışmada, sarsıcı tabla yaklaşımının daha az gürültüyle daha yüksek büyüklükte sinyaller ürettiği, tam uçak konfigürasyonunun ise birleşik bükülme ve burulma durumları da dahil olmak üzere daha gerçekçi özellikler sağladığını bulmuşlardır. Sonuçların iki yöntem arasındaki frekanslarda önemli benzerlikler gösterdiği ancak aynı zamanda serbestlik derecesinin titreşim özellikleri üzerindeki etkisi olduğu vurgulanmıştır. Bu araştırma sonucunda ise optimum performansı ve yapısal bütünlüğü sağlamak için İHA'ların kanat yapılarına yönelik kapsamlı titreşim testlerinin önemi vurgulanmıştır [57].

Zhang vd., quadcopter'ler için hava aracı gövde titreşim sinyallerine dayalı bir FDI yöntemi geliştirmiştir. Geliştirilen yöntemde, uçuş sırasında quadcopter'den üç eksenli ivmelenme verilerini toplamak için hava aracında ivme sensörleri kullanmışlardır. Daha sonrasında ise dalgacık paketi ayrıştırma yöntemi ile veri özelliklerini çıkararak dalgacık paket katsayılarının standart sapmaları ile özellik vektörünü oluşturmuşlardır. Buna bağlı olarak da quadcopter kanat arızalarını etkili bir şekilde tespit eden ve tanımlayan LSTM tabanlı bir FDI modeli oluşturulmuştur. Modelin, geri yayımlı (Backpropagation) sinir ağı tabanlı FDI modeline kıyasla daha yüksek doğruluk elde ettiği belirtilmiştir. Sonuçlar, quadcopter kanat arızalarının gerçek zamanlı tespiti için çok eksenli veri bilgilerinin ve gelişmiş sinyal işleme tekniklerinin kullanılmasının etkinliğini göstermiştir [58].

Ghazali ve Rahiman, İHA'ların kol yapısına odaklanan, İHA'lar için gerçek zamanlı bir anormallik tespit yöntemi geliştirmiştir. Modellerinde, hava aracının kollarından titreşim verileri toplamak ve küçük ve büyük çatlakları tespit etmek için

Mikro-Elektro-Mekanik Sistemler (MEMS) ivmeölçerleri kullanmışlardır. Titreşim sinyalleri, gözlemlenen titreşim seviyelerine göre hava aracının durumunu belirlemek için bulanık mantık algoritması kullanılarak analiz edilmiştir. Deney sonrasında elde edilen sonuçlar sağlıklı hava aracı kollarına kıyasla küçük çatlakların %38 - %50 daha yüksek maksimum genlikler ürettiğini ve büyük çatlakların ise %62 - %71 daha yüksek genlikler ürettiğini göstermiştir. Küçük çatlaklara sahip İHA'ların havada asılı kalabildiği ancak büyük çatlakların hava araçlarının düşmesine neden olduğu belirtilmiştir. Çalışmanın sonunda, kapalı mekan uçuş testleri kullanılarak sonuçların doğrulandığına ve yöntemin gerçek zamanlı izleme ve anormallik tespitindeki başarısına değinilmiştir [59].

Al-Haddad ve Jaber, makine öğrenimi ve ReliefF üstün özellik sıralama yöntemini kullanarak İHA'ların kanat dengesizliğini tahmin etmek için bir yöntem geliştirmişlerdir. Bir quadcopter hava aracının kanatlarına ağırlık ekleyerek kanat hatalarını simüle etmişler ve 3 eksenli bir ivmeölçer ile titreşim verilerini toplamışlardır. RMS, varyans ve standart sapma gibi özellikleri çıkararak, bunlardan en önemli olanlarını belirlemek için ReliefF yöntemini kullanmışlardır. Sonrasında ise SVM ve KNN algoritmaları ile model eğitimi yaparak sırasıyla %98,85 ve %96,41 tahmin doğruluğu elde etmişlerdir. Geliştirilmiş modellerin, temel modellere kıyasla doğrulukta önemli bir gelişme gösterdiği ve işlem süresini kısaltarak İHA'larda gerçek zamanlı hata teşhisinde kullanılabileceğini göstermiştir. Ayrıca bu çalışmada, İHA'larda arıza tespitinde makine öğrenme modellerinin performansını artırmak için özellik seçim yöntemlerinin potansiyeli de vurgulanmaktadır [60].

Al-Haddad vd., titreşim sinyali analizini kullanarak İHA'larda dengesizlik hatalarını sınıflandırmak için frekans alanına dayalı bir yöntem geliştirmiştir. ADXL335 ivmeölçer ve LabVIEW veri toplama sistemi kullanarak DJI Mini 2 Combo marka bir İHA'dan titreşim sinyallerini toplamışlardır. Sonrasında sinyallerin frekans alanı özelliklerini çıkarmak için FFT kullanmışlardır. Yapılan çalışma, titreşim spektrumundaki tepe frekans değişimlerinin gözlemlenerek arızaların karakteristik imzalarını belirlemeye odaklanmıştır. Hasarlı kanatların tepe frekanslarda belirgin kaymalara neden olduğunu ve hatalı rotor durumlarının tanımlanmasına ve izolasyonuna olanak sağladığını ortaya koymuşlardır. Yöntemin, İHA sağlığının gerçek zamanlı izlenmesinde yüksek hassasiyet ve etkinlik gösterdiği belirtilmiştir [61].

Verbeke vd., çok rotorlu İHA'nın kapsamlı bir titreşim analizini gerçekleştirmiştir. Çalışmalarında elektrikle çalışan altı motora ve bunlara bağlı pervanelere odaklanarak

titreşimlerin birincil kaynaklarını analiz etmişlerdir. Hexacopter çerçevesinin ana yapısal bileşenlerinin hem deneysel hem de sayısal modal analizlerini gerçekleştirmişlerdir. Çeşitli yöntemleri kullanarak, hassas elektroniklerin en iyi şekilde monte edilebileceği düşük titreşimli bölgeleri tespit etmişlerdir. Sayısal modal analizi ise, İHA'nın farklı çalışma koşulları altında titreşim davranışını simüle etmek için sonlu elemanlar modelinin oluşturulmasını içermektedir. Çalışma sonuçlarının deneysel ve sayısal veriler arasında iyi bir korelasyon olduğunu gösterdiği ve titreşimden kaynaklanan hataları en aza indirmek için elektronik montajının yapılabileceği kritik alanları gösterdiği belirtilmiştir. Bu analizin, özellikle hassas kontrol ve navigasyon gerektiren uygulamalarda kullanılan İHA'nın stabilitesini ve performansını artırmak için önemli olabileceği belirtilmiştir [62].

Gemayel vd., titreşim analizini kullanarak bir İHA'nın rotor kusurlarını tespit etmek için makine öğrenimine dayalı bir yöntem geliştirmiştir. Modellerinde, uçuş öncesi ve sonrası operasyonlar sırasında hava aracının rotorlarından titreşim verilerini toplamak için ADXL345 ivmeölçerlerden yararlanmışlardır. STFT, Shannon Entropisi ve WPD özellikleri dahil olmak üzere hem zaman hem de frekans alanlarındaki titreşim verilerinden özellikler çıkarılmıştır. PCA gibi boyut azaltma teknikleriyle birleştirilen Random Forest algoritması, en iyi performansı sergileyerek rotor kanadı kusurlarının oldukça iyi bir şekilde tespit edilmesini sağlamıştır. Analizleri, çeşitli özellik alt kümelerinin model performansı üzerindeki önemli etkisini göstermiş ve sınıflandırma karar sürecinde belirli özelliklerin önemini vurgulamıştır. Bu yaklaşım ile, İHA'ların gelecekteki akıllı şehirlerde etkili bir şekilde çalışması için hayati önem taşıyan gerçek zamanlı izleme ve hata tespitinin mümkün kılınabileceği belirtilmiştir [63].

Cocuzza ve Doria, İHA'ların görevleri esnasında maruz kaldıkları titreşimleri modellemek ve tanımlamak için bir yöntem geliştirmiştir. Önemli titreşim modlarını belirlemek ve hava araçlarının dinamik davranışını ölçmek için DJI S1000 octocopter tip hava aracını ve EMA kullanmışlardır. Daha sonra sistemin dinamik davranışını temsil etmek için deneysel verilerden belirlenen parametrelerle basitleştirilmiş bir Kütle-Yay-Sönümleyici (MSD) modeli önermişlerdir. Bu modelin, hava aracının titreşim izolasyon sistemlerinin tasarlanması, hava aracı kaynaklı titreşimlerin etkisinin azaltılması ve görevlerde hassasiyet sağlanması açısından çok önemli olduğu vurgulanmıştır [64].

Al-Mashhadani, İHA'lardaki rastgele titreşimleri yönetmek için bir matematiksel analiz ve kontrol metodolojisi geliştirmiştir. Geliştirilen modelde rastgele titreşimler stokastik bir süreç olarak ele alınmakta, olasılık ve istatistiksel yöntemler kullanılarak

analiz edilmektedir. Çalışma, aerodinamik etkiler ve hava türbülansı gibi atalet ölçüm birimleri ve ivmeölçerler gibi sensörlerden toplanan verilerin doğruluğunu etkileyen çeşitli rastgele titreşim kaynakları göz nünde bulundurulmuştur. Bu titreşimlerin etkilerini azaltmak için olasılık teorisine dayalı bir kontrol metodolojisi önerilmiştir. Analiz esnasında, titreşimleri rastgele ve durağan olmayan bir süreç olarak modellemek için pratik yaklaşım teknikleri kullanılmış ve İHA'nın performansını ve emniyetini korumak için titreşim kontrolüne duyulan ihtiyaç vurgulanmıştır. Bu araştırmanın, hava aracı sistemlerindeki rastgele titreşimleri anlamak ve azaltmak anlamında önemli olduğu belirtilmiştir [65].

Baldini vd., çok rotorlu İHA'lardaki pervane arızalarını tespit etmek için titreşim veri analizine dayalı ve gerçek zamanlı bir arıza tespit yöntemi geliştirmiştir. Modellerinde, gerekli özelliklerin bir alt kümesini çıkarmak için IMU'dan alınmış verileri ve Sonlu Darbe Tepkisi (FIR) filtrelerini birleştirerek kullanmışlardır. Arıza tespit algoritmasını geleneksel ArduPilot tabanlı kontrolörle donatılmış bir hexacopter üzerinde çalıştırmışlar ve Lineer SVM kullanarak %98,21'e varan sınıflandırma doğruluğu elde etmişlerdir. Önerilen yöntemin, PixHawk Cube uçuş kontrol cihazının döngü süresinin %2'sinden daha azını gerektiren sınırlı hesaplama kaynaklarıyla çalışacak şekilde tasarlandığı belirtilmiştir. Çalışma sonuçlarının ek sensörler veya yüksek hesaplama gücü olmadan gerçek zamanlı arıza tespitinin yapılabileceğini gösterdiği ve bu durumun da çoğu kullanıma hazır İHA için uygun olduğu belirtilmiştir. Çalışmanın çeşitli çok rotorlu araçlara uygulanabileceği ve uçuş sırasında arızanın anında tespit edilmesini sağlayarak operasyonel güvenilirliği arttırabileceği belirtilmiştir [66].

Liao vd., dört rotorlu İHA'lar için kanat hasarının yer tespitine yardımcı olmak amacıyla bir Uzaysal Titreşim Modülasyon Metodu (SVMM) geliştirmişlerdir. Modellerinde, İHA'nın bağlantı noktalarına monte edilen, rastgele seçilmiş yapısal parametrelere sahip, silikondan yapılmış halka şeklindeki vibratörleri kullanmışlardır. Bu durumun, her bir bağlantı noktası için farklı frekans transfer fonksiyonları oluşturarak, tek bir sensörün titreşim kaynaklarını tanımlamasına yardımcı olduğu belirtilmiştir. Çalışmada, tekli hasar durumları için %97 ve ikili hasar konumları için %86 doğruluk elde edilerek, pervane hasarının yerinin tespit edilmesi için yüksek tanıma doğruluğu elde edildiği belirtilmiştir. SVMM yönteminin, İHA'ya birden fazla sensöre ihtiyaç duymadan kanat hasarını tespit etme yeteneği verdiği ve böylece maliyet ile karmaşıklığın azaltıldığı vurgulanmıştır [67].

Özkat, titreşim verilerini kullanarak İHA'larda anormallik tespiti için derin öğrenmeye dayalı bir yöntem geliştirmiştir. Çalışmada titreşim sinyallerini izlemek için Dalgacık Saçılımlı LSTM otomatik kodlayıcı ağı kullanılmıştır. Bir DJI M600 çok rotorlu İHA'da MTi-G-700 marka ivmeölçer kullanarak veriler toplanmış ve bir pervane kanadını değiştirerek kasıtlı olarak titreşimler oluşturmuşlardır. Dalgacık saçılım tekniği frekans dinamiklerini yakalarken, LSTM otomatik kodlayıcı zamansal kalıpları öğrenerek normal davranıştan sapmaları etkili bir şekilde tanımlamıştır. Modelin, arızalar meydana gelmeden önemli ölçüde önce üretilen uyarı sinyalleri ile erken arıza tespitinde yüksek doğruluk sergilediği belirtilmiştir. Çalışmada önerilen yöntemin, gerçek zamanlı anormallik tespitinde başarı göstererek bir İHA'nın emniyetini artırma potansiyeli olduğu vurgulanmıştır [68].

Jawad ve Jaber, titreşim sinyali analizine dayalı rulman arıza tespiti için bir yöntem geliştirmiştir. İç ve dış yatak arızalarının yanı sıra birleşik kafes ve bilye arızaları da dahil olmak üzere çeşitli yatak arızalarını simüle eden deneysel bir test donanımı oluşturmuşlardır. Farklı çalışma koşulları altında titreşim sinyallerini toplamak için DAQ USB-6215 cihazıyla birlikte bir ADXL335 ivmeölçer kullanılmıştır. Öncelikle, zaman alanında bulunan titreşim verileri, FFT kullanılarak frekans alanına dönüştürülmüştür. Çalışma, karakteristik arıza frekanslarını belirlemek için dönüştürülen bu sinyallerin analiz edilmesini ve yöntemin etkinliğini doğrulamak için bunların teorik değerlerle karşılaştırılmasını içermektedir. Yazarlar, daha yüksek titreşim genliklerinin belirli arıza frekanslarına karşılık geldiğini belirtmiş ve bu durumun da yöntemin farklı rulman sağlığı durumlarına karşı duyarlı olduğunu vurgulamışlardır. Titreşime dayalı arıza teşhis tekniklerinin, özellikle değişen yükler ve hızlar altında etkili olduğu sonucuna varmışlar ve gelişmiş arıza tespit doğruluğu için makine öğrenme algoritmalarıyla gelecekte entegrasyon yapılmasını önermişlerdir [69].

Bondyra vd., çok rotorlu İHA'larda pervane hasarını tespit etmek için bir FDI sistemi geliştirmiştir. Yöntemleri, itki ünitelerinin yakınına yerleştirilen MEMS ivmeölçerlerini kullanarak eksenel ve radyal titreşimlerin ölçülmesini içermektedir. Karakteristik arıza imzalarını çıkarmak için FFT kullanarak titreşim sinyallerini işlemişlerdir. Bu imzalar daha sonra hasarlı pervaneleri tespit etmek ve yerini belirlemek için bir dizi rastgele karar ağacı kullanılarak sınıflandırılmıştır. Sistem, hatalı rotor durumlarını tespit etme ve izole etmede %95'in üzerinde hassasiyet sergileyen çok sayıda test uçuşuyla doğrulanmıştır. Yaklaşım, etkili ve düşük maliyeti olması ile dikkat

çekmekte ve bu durum da onu çeşitli İHA uygulamaları için uygun kılmaktadır. Sonuçlar ise, arıza durumlarına karşılık gelen önemli titreşim modellerini göstermekte ve bu durum da yöntemin güvenilir arıza teşhisi sağlama yeteneğini göstermektedir [70].

Yoon vd., eğik(Skew) durumdaki İHA'larda sensör arızalarını teşhis etmek için hibrit bir FDI sistemi geliştirmişlerdir. Bunun için, ayrık dalgacık dönüşümüne dayanan şerit içi izleme yöntemiyle eşlik alanı yöntemini birleştirmişlerdir. Modellerinde, birden fazla ardışık hataya karşı sistem toleransını artırmak için birincil ivmeölçere eğik bir açıyla ek bir düşük maliyetli ivmeölçer yerleştirilmiştir. Birinci ve ikinci arızalar eşlik alanı yöntemi kullanılarak tespit edilip izole edilirken, üçüncü arıza eşlik alanı yöntemiyle tespit edilip şerit içi izleme yöntemiyle izole edilmiştir. Sistemin performansı, donanım testleri ve sabit kanatlı bir İHA ile uçuş deneyleri yoluyla ölçülmüştür. Sonuçlar, hataların tespit edilmesinde ve izole edilmesinde yüksek hassasiyet ve doğruluk göstererek yöntemin İHA uygulamaları için etkin ve pratik olduğunu göstermektedir [71].

Lee vd., kararlı durum modelinin doğrusal olmayan parametrelerine dayalı olarak İHA motorları için bir arıza sınıflandırma ve teşhis yöntemi geliştirmişlerdir. Yaklaşımlarında, doğrusal olmayan denklemler kullanarak normal kararlı durum koşulları altında hava aracının motoru için bir model türetmişler ve deneysel doğrulamalarında %99 doğruluk elde etmişlerdir. Çalışma, rulman sürtünme artışı, faz açıklığı, pervane hasarı, transistör açıklığı ve sinyal hataları dahil olmak üzere çeşitli İHA motor arızalarının belirlenmesine odaklanmıştır. Önerilen teşhis algoritması, farklı arıza türlerini ayırt etmek için kararlı durum koşullarından yararlanarak her arızanın özelliklerini analiz etmektedir. Yöntemi, seçilen tüm hataların başarılı bir şekilde teşhis edildiğini gösteren kapsamlı test ortamı deneyleriyle doğrulamışlardır. Ek olarak, bir hexacopter ile yapılan uçuş testleri teşhis tekniğinin gerçek dünya senaryolarında uygulanabilirliğini göstermiş ve stabil koşullarda yaklaşık %98 teşhis doğruluğu elde etmiştir. Sonuçlar, önerilen tekniğin birden fazla arıza tipini etkili bir şekilde teşhis edebildiğini ve İHA'ların motor bakımı ve arıza önleme için güvenilir bir temel sağladığını göstermektedir [72].

Saied vd., bir octocopter İHA'daki motor arızalarını ve rotor hasarlarını teşhis etmek için hataya dayanıklı bir kontrol stratejisi geliştirmişlerdir. Geliştirilen modelde hata tespiti ve arıza izolasyonu için motorların hız ve akım ölçümlerinden yararlanılmıştır. Teşhis sistemi, motor arızaları ile pervane kayıpları arasında ayırım yaparak arıza tipini sınıflandırmak için SVM kullanmaktadır. Arıza tespiti olduğunda,

kontrol yaklaşımı, sürekli çalışmayı sağlamak için kontrol görevlerini sağlıklı aktuatörler arasında yeniden belirlemektedir. Mimarının, etkili hata tespiti ve sistem kurtarmayı gerçek uçuş deneyleriyle doğrulandığı belirtilmiştir. Kontrolün aktuatörler arasında yeniden tahsisinin, octorotorun birden fazla eşzamanlı motor arızasından sonra bile stabiliteyi ve kontrolü korumasına olanak sağladığı vurgulanmıştır [73].

Ghahamchi vd., multikopterlerdeki pervane arızalarını teşhis etmek için gerçek zamanlı titreşime dayalı bir yöntem geliştirmişlerdir. Geliştirilen modelde, titreşim miktarını motor komutlarıyla ilişkilendirmek ve pervanenin dengesizlik büyüklüğünü tahmin etmek için ivmeölçer çıkış verilerine bakılmıştır. Yöntemleri, zaman alanında yinelemeli bir uygulamaya dayanmakta ve minimum düzeyde hesaplama ve bellek gereksinimine ihtiyaç duymaktadır. Bu yaklaşımın, farklı kütlelere ve motor tiplerine sahip quadcopter'ler ve hexacopter'ler dahil olmak üzere üç farklı multicopter platformu üzerinde yapılan deneylerle doğrulandığı belirtilmiştir. Sonuçlar, algoritmanın spesifik hasarlı motor/pervane çiftini başarılı bir şekilde tanımlamasıyla hatalı pervanelerin güvenilir bir şekilde tespit edilebildiği göstermiştir. Yöntemin, uyarlanabilirliğini ve düşük maliyetli olması öne çıkarılarak farklı araç boyutları ve tasarımlarında etkili bir şekilde çalışabileceği vurgulanmıştır. Sonuç olarak, bu çalışma etkili bir arıza teşhis mekanizması sağlayarak çoklu helikopterlerin güvenilirliğini ve emniyetini artırmaya bulunmaktadır [74].

Marichal vd., İHA'lardaki görüş sistemlerini etkileyen titreşimleri azaltmak için nöro-bulanık(Neuro-Fuzzy) bir kontrolör geliştirmişlerdir. Geliştirilen modelde, bir titreşim izolasyon sisteminin sönümleme katsayısını gerçek zamanlı olarak ayarlayabilmek için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) kullanmışlardır. Sistemin performansı, kameranın stabilitesine odaklanarak helikopter titreşimlerini simüle eden dinamik bir platform kullanılarak test edilmiştir. Önerilen yöntemi geleneksel pasif titreşim azaltma teknikleriyle karşılaştırmışlar ve özellikle titreşime maruz kalmanın ilk aşamasında üstün performans gösterdiğini ortaya koymuşlardır. Nöro-bulanık yaklaşım, titreşimlerin görüş sistemi üzerindeki zararlı etkisini azaltarak daha stabil görüntüler sağlamıştır. Bu yöntem ile tutarlı görüntü kalitesi sağlayarak İHA'nın operasyonel güvenilirliğinin artırılması hedeflenmiştir [75].

Ranjan vd., mini helikopterlere elektro-optik faydalı yüklerinin takılabilmesi için bir titreşim ölçüm yöntemi geliştirmişlerdir. Çalışmalarında helikopterin temel titreşim profilini çıkarmışlar ve pasif titreşim yalıtıcılarının elektro-optik yükü ile stabilize video

elde etmedeki etkinliğini analiz etmişlerdir. Motor ve rotor kanatlarını mekanik, aerodinamik ve akustik titreşimlerin ana kaynakları olarak tanımlamışlardır. Titreşimlerin ivmeölçerler kullanılarak uçak gövdesinin farklı konumlarında ölçüldüğü ve verilerin hem zaman hem de frekans alanlarında analiz edildiği vurgulanmıştır. Çalışmada izolatörsüz, tel halat izolatörlü ve kalıplanmış lastik top izolatörlü olmak üzere üç farklı konfigürasyon test edilmiştir. Sonuçlar, çok aşamalı pasif izolatörlerin kullanılmasının titreşimleri önemli ölçüde azalttığını ve böylece video stabilitesinin arttığını göstermiştir [76].

Bektash ve la Cour-Harbo, titreşim analizini kullanarak İHAlardaki anormallikleri tespit etmek için bir yöntem geliştirmişlerdir. Yaklaşımlarında, rotorlu tipte bir İHA kullanarak taşıt üzerine monte edilmiş IMU sensörlerini kullanarak çeşitli uçuş koşullarından titreşim verilerini kaydetmişlerdir. Titreşim sinyallerinin güç spektral yoğunluğunu tahmin etmek için Welch yöntemini kullanmışlar ve anormallikleri gösteren kalıpları tanımlamak için verileri döngülere ayırmışlardır. Çalışmada, yöntemin farklı yük koşulları altında test edilmesini içerdiği ve normal ve anormal uçuşlar arasındaki titreşim seviyelerindeki önemli farklılıkları ortaya çıkardığı belirtilmiştir. Sonuçlar, önerilen yöntemin uçuş sırasındaki anormallikleri başarılı bir şekilde tanımlayıp ölçebildiğini göstermiştir. Bu nedenle yöntemin, İHA operasyonlarında gerçek zamanlı izleme ve hata tespiti potansiyeli olduğu vurgulanmıştır [77].

Puchalski ve Giernacki, özellikle titreşime dayalı yaklaşımlara odaklanarak İHA'larda hata tespitine yönelik çeşitli yöntemleri incelemişlerdir. İncelemelerinde İHA'nın güvenliğini artırmak için güvenilir hata tespitinin önemi vurgulanmış, model tabanlı ve veriye dayalı yöntemler dahil olmak üzere farklı teknikleri tartışmışlardır. Titreşim verilerinden arızaları teşhis etmek için özellikle istatistiksel analiz, sinir ağları ve sinyal işleme tekniklerini kullanan yöntemlerin üzerinde durmuşlardır. İnceleme, her yaklaşımın güçlü ve zayıf yönlerini detaylandıran farklı çalışmaların kapsamlı bir karşılaştırmasını içermektedir. Araştırmacılar, arıza tespitinin doğruluğunu artırmak için karmaşık sensörlerin ve gelişmiş algoritmaların artan kullanımına da dikkat çekmektedirler. Ayrıca pratik senaryolarda uygulanabilirliğini sağlamak için bu yöntemlerin gerçek dünyada test edilmesinin ve doğrulanmasının önemini belirtmişlerdir. Çalışma, özellikle İHA'larda arıza tespiti araştırmasındaki en son gelişmelere ve gelecekteki duruma ilişkin bilgiler sağlayarak İHA'ların güvenilirliğini korumada titreşim analizinin kritik rolünün altını çizmektedir [78].

Gorospe ve Kulkarni, İHA'lardaki elektrikli itki sistemlerinin diagnostikleri ve prognostikleri için yeni bir donanım (Hardware In the Loop) test ortamı geliştirmişlerdir. Edge 540T uçağını referans alan modelleri, kontrollü ve izole edilmiş bir laboratuvar ortamında, motorlar, hız kontrolörleri ve pillerden oluşan bir itki sistemini içermektedir. Test ortamı, mekanik aşınmayı simüle ederek değişken mekanik direnç sağlayan bir yardımcı motor aracılığıyla uçuş benzeri yüklerin uygulanması yoluyla teşhis ve prognostiklere olanak tanımaktadır. Çalışmaları, her bir bileşenin matematiksel modellerinin doğrulanmasını ve hata analizi için tekrarlanabilir uçuş benzeri koşulların oluşturulmasını sağlamaktadır. Test ortamı, uzaktan veri yayınlama ve havadaki araçlarla senkronizasyon için LabVIEW tabanlı bir istemciyle birlikte kurgulanmıştır. İlk deneyler, sabit yükleme koşulları altında nominal ve bozulmuş Elektronik Hız Kontrolcüsü (ESC) arasındaki performans farklarını gözlemlemeye odaklanmıştır [79].

Tahir vd., zaman alanlı titreşim sinyallerini kullanarak rulman arızalarını teşhis etmek için yeni bir yöntem geliştirmişlerdir. Rulman arızalarının güvenilir bir şekilde sınıflandırılmasını sağlayan, titreşim sinyallerinden doğru zaman alanı özelliklerini elde etmek için merkezi eğilim tabanlı özellik çıkarma (CTBFE) yöntemini önermişlerdir. CTBFE yöntemi, titreşim sinyallerini daha küçük parçalara ayırmayı ve her bölümden RMS, mean, variance, skewness, and kurtosis gibi özelliklerin çıkarılmasını içermektedir. Yöntem, bu özelliklerin merkezi eğilimine odaklanarak geleneksel özellik çıkarma yöntemlerinin teşhis yeteneğini sıklıkla bozan sinyal dalgalanmalarının ve aykırı değerlerin etkisini azaltmaktadır. Yaklaşımlarını, SVM, BayesNet, Karar Tablosu ve DT dahil olmak üzere çeşitli sınıflandırıcılar kullanılarak doğrulamış ve önemli ölçüde geliştirilmiş hata sınıflandırma doğruluğu ortaya çıkmıştır. Araştırmacılar, bu yöntemin hesaplama açısından verimli ve gerçek zamanlı uygulamalar için uygun olduğunu bunun da onu rulman arızalarının güvenilir şekilde tanınması için sağlam bir çözüm haline getirdiğini vurgulamaktadırlar [80].

Jiang vd., hava aracı gövdesi titreşim sinyallerini kullanarak dört rotorlu motorlarda arıza tespiti ve tanımlanması için veriye dayalı bir yöntem geliştirmişlerdir. Özellik vektörleri oluşturmak için dalgacık paket katsayılarının standart sapmalarını çıkararak titreşim sinyallerini analiz etmek için üç seviyeli dalgacık paketi ayrıştırmasını kullanmışlardır. Bu özellik vektörleri daha sonra rotor arızalarını teşhis etmek için bir Yapay Sinir Ağı (ANN) ile işlenmiştir. ANN'nın çıkışının rotorların sağlık durumunu yansıttığı belirtilmiştir. Yöntemin etkinliğinin ve performansının farklı rotor

arızalarından alınan titreşim sinyali özelliklerine göre başarılı bir şekilde tespit edilebildiği vurgulanmıştır [81].

Chandra ve Rao, indüksiyon motorlarında kullanılan çift sıralı rulmanlardaki arızaları teşhis etmek için titreşime dayalı bir yöntem geliştirmişlerdir. Yaklaşımlarında, motorun orta ve uç kısımlarından gelen titreşim sinyallerini izlemek için bir FFT yöntemi kullanmışlardır. IMU sensörleri ile hem tam yük hem de yüksüz koşullar altında üç eksenli yönde titreşim verilerini toplamışlardır. Genlik, spektrum ve zaman dalga biçimi sinyallerini analiz ederek özellikle harmonik frekanslardaki genlik tepe noktalarına odaklanarak rulman arızalarını belirlemişlerdir. Rulman arıza frekanslarına ilişkin teorik hesaplamaları gözlemlenen titreşim verileriyle eşleşerek arızanın doğru bir şekilde tespit edilmesini sağlamıştır [82].

Stupar vd., helikopter yapılarındaki kusurları titreşim analizi yoluyla tespit etmek için kapsamlı bir metodoloji geliştirmişlerdir. Dönen bileşenlerin durumunu değerlendirmek için helikopter yapısının belirli yerlerinde titreşim ölçümlerinden yararlanmışlardır. Çeşitli uçuş profilleri için frekans alanındaki boylamsal ve dikey titreşimlere odaklanarak potansiyel kusurları tespit ettiklerini belirtmişlerdir. Metodoloji, uçuş testleri sırasında helikopterin stratejik noktalarına yerleştirilen IMU'lar kullanılarak titreşimlerin ölçülmesini içermektedir. FFT analizi sayesinde yapısal kusurların göstergesi olan önemli genlik değişiklikleri tespit etmişler ve bu yaklaşımın arızaların zamanında tespit edilmesinde ve helikopter bileşenlerinin operasyonel ömrünün uzatılmasında etkili olduğunu vurgulamışlardır [83].

Plasencia vd., görüş sistemi ile donatılmış bir insansız helikopterdeki titreşimlerin modellenmesi ve analiz edilmesi için bir yöntem geliştirmişlerdir. Ana rotordan kaynaklanan bir dizi titreşim oluşturmak için VehicleSim'i kullanmışlar ve Simmechanics yazılımını kullanarak bunların gövde üzerindeki etkilerini analiz etmişlerdir. Modellerinde titreşimleri simüle etmek için yapay olarak dengesizlikler oluşturmuşlar ve bu titreşimleri azaltmak için ANFIS kontrol metodolojisini kullanmışlardır. Titreşimlerin hava aracında takılı görüş sistemi üzerindeki etkisine odaklanan simülasyonlar, ANFIS tabanlı kontrolün istenmeyen hareketleri etkili bir şekilde azalttığını ve böylece görüntü stabilitesini iyileştirdiğini göstermiştir. Çalışmada, İHA'ların görüş sistemlerinin performansını artırmak için titreşim özelliklerini anlamının ve uyarlanabilir kontrol sistemlerinin uygulanmasının önemi vurgulanmıştır [84].

Jin vd., iz oranı doğrusal diskriminant analizini (TR-LDA) kullanarak motor rulman arızalarını teşhis etmek için titreşime dayalı bir yöntem geliştirmişlerdir. Modellerinde boyut küçültme ve hata sınıflandırması için TR-LDA uygulayarak yüksek boyutlu, Gaussian olmayan hata verilerini ele almışlardır. Yaklaşım, hem tek noktalı hatalar hem de genelleştirilmiş pürüzlülük hataları dahil olmak üzere titreşim sinyallerinden özelliklerin çıkarılmasını ve hata teşhis probleminin bir model tanıma görevine dönüştürülmesini içermektedir. TR-LDA'nın performansını PCA ve doğrusal diskriminant analizi (LDA) gibi diğer geleneksel yöntemlerle karşılaştırmışlar ve TR-LDA'nın üstün hata teşhis yeteneği olduğunu belirtmişlerdir. Yöntemleri, sınıf içi saçılımı en aza indirirken, sınıflar arası saçılımı etkili bir şekilde maksimuma çıkararak farklı hata sınıfları arasındaki ayrımı arttırmıştır [85].

Saucedo-Dorantes vd., dişli kutularındaki aşınmayı ve asenkron motorlardaki rulman kusurlarını teşhis etmek için titreşim ve akım analizine dayanan çoklu arıza tespit metodolojisi geliştirmişlerdir. Modellerinde, sırasıyla üç eksenli bir IMU, Hall etkisi sensörlerinden elde edilen titreşim ve akım sinyallerinden FFT ve Güç Spektral Yoğunluğunu (PSD) kullanarak arızaya ilişkin spektral bileşenleri çıkarmışlardır. Çalışmaları, dişli kutularındaki düzgün aşınmanın ve kinematik zincirdeki rulman kusurlarının tespit edilmesine odaklanmıştır. Önerilen metodoloji, karakteristik arıza frekanslarını hesaplamak için teorik modellemeyi ve bu frekanslardaki genlik değişikliklerini tanımlamak için sinyal işlemeyi içermektedir. Çalışma sonucunda, metodolojinin dönen makinelerdeki çoklu arızaları etkili bir şekilde tanımlayabildiği vurgulanmıştır [86].

Henriquez vd., titreşim ve ses sinyallerini kullanan otomatik arıza teşhis sistemlerindeki son gelişmeleri incelemişlerdir. Durum izleme (Condition Monitoring-) ve arıza teşhisinin, önemli mali kayıplara ve güvenlik tehlikelerine yol açabilecek beklenmedik arızaları önleyerek operasyonel süreklilikte çok önemli bir rol oynadığını vurgulamışlardır. Makalede sinyalin elde edilmesi, sinyal işleme, karar desteği ve hata teşhisi de dahil olmak üzere bir durum izleme sisteminin aşamaları ayrıntılı olarak anlatılmıştır. Arıza tespiti amacıyla titreşim ve ses sinyallerinden özellikler çıkarmak için kullanılan FFT, PSD ve zaman-frekans analizi gibi çeşitli sinyal işleme tekniklerini tartışmışlardır. Çalışmalarında, teşhis doğruluğunu artırmak için AI'ı bu tekniklerle entegre etmenin etkinliği vurgulanmıştır. Çalışmada ayrıca, gürültü giderme tekniklerinin geliştirilmesi ve ses tabanlı arıza teşhisinde kaynak ayrımı için sağlam

algoritmalar geliştirilmesi gibi alandaki zorluklara ve potansiyel araştırma yönlerine de dikkat çekilmiştir [87].

Dunbabin vd., İHA'larda bulunan sensörlerin güvenilir ve doğru çalışmasını sağlamak amacıyla otonom helikopter uçuşu için bir titreşim izolasyon sistemi geliştirmişlerdir. Modellerinde CSIRO otonom X-Cell helikopteri için entegre izole görüş ve sensör platformu ile iniş takımı tasarlamışlardır. Etkili titreşim izolasyonu elde etmek için düşük sertlikteki yaylar, küçük viskoz sönümleyiciler ve yumuşak köpük halkalardan oluşan bir kombinasyon kullanmışlar ve %20'den daha düşük bir aktarım oranı hedeflemişlerdir. Sistemin, özellikle 25 Hz'lik frekans civarında iletilen titreşimlerde önemli bir azalma gösterdiği belirtilmiştir. Araştırmacılar, uygun yay ve sönümleme malzemelerinin sınırlı bulunması nedeniyle istenen izolasyon performansına ulaşmanın zorluklarını vurgulamışlardır [88].

Nandi vd., elektrik motorlarının durum izlemesi ve arıza teşhisi konusunda kapsamlı bir inceleme gerçekleştirmişlerdir. Çalışmaları, rulman arızaları, stator arızaları, kırık rotor çubukları ve eksantriklikle ilgili sorunlar gibi çeşitli arızaların belirlenmesine odaklanmaktadır. Hat akımındaki harmonik bileşenler aracılığıyla arızaları tespit etmek için MCSA'nın önemini vurgulamışlardır. Yazarlar ayrıca hız, tork, gürültü ve titreşim analizi dahil diğer teşhis tekniklerini de tartışmışlardır. Uzman sistemler, sinir ağları ve bulanık mantık tabanlı sistemler gibi otomatik araçların hata tespitinde insan müdahalesini azaltan teknolojilerin artan kullanımına da vurgu yapmışlardır. Çalışmaları aynı zamanda arıza teşhisi için termal ölçümlerin ve kimyasal analizlerin kullanımını da ele almaktadır. Bu çalışma, farklı hatalara ve teşhis şemalarına genel bir bakış sunmaktadır [89].

2. ELEKTRİKLİ HAVA ARACININ MODELLENMESİ

Tez çalışması dahilinde, sistem mühendisliği kavramlarından biri olan MBSE kavramı SysML ile birlikte öğrenilmiş ve sonrasında MBSE yaklaşımı kullanılarak bir elektrikli hava aracının sistem modellenmesi yapılmıştır. Sistem modellenmesi, tez çalışmasının ileriki aşamalarında yapılan ve tez konusunu oluşturan diagnostik uygulamalarının sistemin karmaşık yapısından soyutlayarak, basit ve gerçekçi olmasını sağlamıştır.

2.1. Model Tabanlı Sistem Mühendisliği (MBSE)

MBSE için, karmaşık sistemlerin geliştirilmesiyle ilgili gereksinimleri, tasarımı, analizi, doğrulamayı ve onaylamayı desteklemek için kullanılan resmileştirilmiş bir metodolojidir denilebilir. MBSE'nin temel özelliğine bakıldığında, sistem tasarımlarını geleneksel belge merkezli yaklaşımlardan bir sistemin farklı yönlerini temsil eden modellerin kullanılmasına doğru evrimleştirdiği söylenebilir. Bu modeller; gereksinimler, davranış, yapı, arayüzler ve kısıtlamalar gibi çeşitli sistem unsurlarını kapsayarak sistemin bütünsel bir görünümünün resmedilmesini kolaylaştırmaktadır. Bu metodoloji sayesinde karmaşık sistemler daha etkili ve basit şekilde modellenerek tüm sistemlerin her noktasının ayrıntılı şekilde tasarlanabilmesi ve analiz edilmesi mümkün olmaktadır. Sistemlerin modellenmesi esnasında bilgisayar üzerinde çalışan dijital modelleme ortamları kullanılmaktadır. Son yıllarda özellikle bilgisayar sistemlerinde olan gelişmeler ve bilgisayarların işlem güçlerinin katlanarak artması sonucunda, dijital modelleme ortamlarının kullanımı yaygınlaşmış ve araştırmacılar bu dijital modelleme ortamlarını kullanarak başarılı sistem modellemeleri yapmaya başlamıştır. Sistem modellemelerinin dijital ortamlar üzerinden yapılmasının benimsenmesi beraberinde özellikle sistem mühendisliği kavramının da gelişmesine olanak sağlamıştır. MBSE kavramı, model, sistem düşünmesi ve sistem mühendisliği kavramları ile birlikte ele alınmaktadır. MBSE'nin anahtar noktalarına bakılacak olursa, bunlar şu şekilde özetlenebilir;

- **Model Merkezli Yaklaşım:** Bu metodolojide modeller, sistem gereksinimlerini, mimariyi, davranışı ve kısıtlamaları tanımlamak ve iletmek için kullanılan birincil unsurlardır. Bu nedenle modeller sistem için tek ana kaynak olarak hizmet etmektedirler.

- Entegre Modeller: Fonksiyonel gereksinimler, fiziksel mimari ve davranış gibi sistemin farklı yönleri, birleşik bir modele entegre edilir. Bu entegrasyon, sistem genelinde tutarlılık ve izlenebilirliğin sağlanmasına yardımcı olur. Ayrıca bir sistemin kolay ve anlaşılır olarak ifade edilmesinde de anahtar noktalardan biri olduğu söylenebilir.
- Yeniden Kullanılabilirlik: Özellikle program içerisinde diğer kısımlardan soyutlanarak geliştirilmiş modeller, farklı projelerde veya sistem değişkenlerinde yeniden kullanılabilir. Bu durum tutarlılığı, verimliliği desteklemekte ve yeni bir hava aracı modellemesi yapılacağı zaman kolaylık sağlamaktadır.
- Sistem Analizi: Sistem davranışını, performansını ve diğer nitelikleri değerlendirmek için modeller analiz edilebilir ve simüle edilebilir. Bu, sorunların erken tespitini, gereksinimlerin doğrulanmasını ve sistem tasarımının optimizasyonunu sağlamaktadır.
- İzlenebilirlik ve Dokümantasyon: MBSE, sistem geliştirme yaşam döngüsü boyunca gereksinimlerin, tasarım kararlarının ve diğer eserlerin izlenebilirliğini vurgulamaktadır. Bu izlenebilirlik sistemin evriminin net bir şekilde anlaşılmasına yardımcı olmakta ve “Verification” ve “Validation” için bir temel sağlamaktadır.

Oluşturulan model, bir şeyin basitleştirilmiş bir versiyonudur ve bazı karmaşıklıkları ortadan kaldırmak için gerçekliği soyutlayan grafiksel, matematiksel veya fiziksel bir temsildir. Bu tanım, basitleştirme, temsil etme veya soyutlamada izlenecek yol veya kurallar anlamına gelmektedir. Bir sistemi modellemek için uğraşan bir sistem mimarı, oluşturacağı sistem yapısını ve davranışını belirgin ve karmaşıklığını ise yönetilebilir olacak şekilde daha az ayrıntıyla temsil etmelidir. Diğer bir deyişle, modeller sistemi yeterince temsil etmeli ve sistem modelleri desteklemelidir.

İncelenmekte veya geliştirilmekte olan bir sisteme kendi kendine bir varlık olarak değil, daha büyük bir sistemin parçası olarak bakmanın bir yolu ise Sistem Düşünmesi'dir. Sistem düşünmesi iyi planları takip etmeye, istatistik toplamaya veya metod tabanlı olmayı gerektirir. Sistem mühendisi, sistemi uzaktan gözlemler, sınırlarını, bağlamını ve yaşam döngüsünü araştırır, davranışını not eder ve kalıpları tanımlar. Bu yöntem, mühendisin sorunları (süreçteki eksik bir adım, tekrarlanan görevler vb.) belirlemesine ve bir sistemin karmaşıklığını yönetmesine yardımcı olabilir. Sistem mühendisleri, sistem düşüncesiyle başlangıçta sistemi parçalara ayırıp analiz etmek

(parçaları belirlemek ve aralarındaki bağlantıları tanımlamak) zorunda olsalar da, daha sonra parçaları tekrar tutarlı bir bütün halinde sentezlerler. Parçalar sadece diğer parçalara bağlı değildir, düzgün çalışması için birbirlerine de bağlıdır. Sistem düşüncesi bu birbirine bağlılığı vurgular. Sistemin davranışı, sistemin alt sistemlerinin aktivitelerinden ortaya çıkmaktadır. Sistem mühendisi, sistemin ara bağlantılarını gözlemleyerek, ilk başta belirgin olmayabilecek geri bildirim döngülerini ve nedensellik modellerini tanımlar. Sistem düşünmesi, sorunları daha belirgin hale getirmeye, tanımlamayı kolaylaştırmaya, sistemi dengelemeye ve sistemin karmaşıklığını yönetmeye yardımcı olabilir.

Sistem mühendisliği, sistem ilkelerini, kavramlarını ve bilimsel, teknolojik ve yönetim yöntemlerini kullanarak mühendislik sistemlerinin başarılı bir şekilde gerçekleştirilmesini, kullanılmasını ve kullanımdan kaldırılmasını sağlamak için disiplinler arası ve bütünleştirici bir yaklaşımdır. Tasarlanan sistem tarafından tüm gereksinimlerin karşılandığından emin olmak için bir dizi tekniği bir araya getirir. Yaşam döngüsü boyunca bir sistemin mimarisine, uygulanmasına, entegrasyonuna, analizine ve yönetimine odaklanır. Ayrıca sistemin yazılım, donanım, personel, süreçler ve prosedürel yönlerini de dikkate bu esnada dikkate alır.

Sistem mühendisi bir sistemi modellerken, yapı, iç iletişim veya emniyet gibi sistemin hangi yönlerinin en önemli olduğuna karar verir ve bu tür yönler, modelin odak noktası haline gelir. Modelleme faaliyetinin en önemli amacı, modelin odaklandığı göze çarpan yönleri mümkün ve uygulanabilir olduğu kadar gerçek sisteme yakın bir şekilde modellemektir.

Modelleme tekniğinin temel dayanak noktalarından en önemli iki tanesi modelde kullanılan dil ve modelin yapısıdır. MBSE, standartlaştırılmış ve yaygın dilleri kullanarak, sistemin anlaşılması için grafiksel gösterim sağlayarak aynı proje üzerinde çalışacak kişilerin iletişimi kolaylaştırmaktadır. Diğer yandan, MBSE, tasarım ile ilgili alternatiflerin keşfedilmesine ve sistem davranışının geliştirme sürecinin erken safhalarında analiz edilmesine olanak da sağlamaktadır. Bu durum, kişilerin sistem performansını simüle etmesini, eksiklikleri değerlendirmesine ve gereksinimleri daha detaylı bir şekilde belirleyebilmesine veya tasarımdaki olası sorunları veya çatışmaları erkenden tespit etmesine olanak tanır. Tüm bu avantajları ile tasarımların optimize edilmesine yardımcı olur, böylece yapılabilecek herhangi bir değişiklikle ilgili maliyet ve riskler de azaltılmış olur.

2.1.1. Modelleme dili

Modelleme dili, modelin yakaladığı soyut bir fikri açıkça iletmek için kullanılan yaygın bir terminolojidir. Modelleme dili, katı sözdizimi ve kuralları ile resmi olabilir. SysML ve Birleşik Modelleme Dili (UML) gibi genel amaçlı dillerin yanı sıra Mimari Analiz Tasarım Dili (AADL) gibi özel diller de dahil olmak üzere birkaç sistem modelleme dili mevcuttur. SysML ve UML matematiksel olarak biçimsel olmasa da, çevrenin modellenmesinde modelleme dilinin kurallarına uyulmasını gerektirir. SysML'nin, belirsizliği önlemeye yardımcı olan, öğeler arasındaki ilişkiler ve bağlantılar için katı sözdizimi ve kuralları vardır. Bir model iyi oluşturulmuşsa, birkaç tür standart SysML diyagramı dinamik olarak simüle edilebilir.

SysML, UML'e dayalıdır ve UML'in yeteneklerini sistem mühendisliğinin benzersiz ihtiyaçlarını karşılayacak şekilde genişletmektedir. Sistem mühendislerinin sistem gereksinimlerini yakalamasına, sistem mimarisini tanımlamasına ve sistemin davranışını ve yapısını modellemesine olanak tanımaktadır. Sistem modellemelerinde kullanılan ve tez çalışması içerisinde de kullanılmasına karar verilen SysML dili UML diline benzemekle birlikte UML'den daha resmidir. Ayrıca iyi yapılandırılmış bir model, özellikle karmaşık sistemler için önemli olan anlaşılabilirlik, kullanılabilirlik ve bakım yapılabilirlik kavramlarının gerçekleştirilmesini sağlamada önemlidir.

Bu bilgiler ışığında, MBSE, sabit kanatlı İHA'lar da dahil olmak üzere her türlü hava aracının tasarlanması ve geliştirilmesinde faydalı olabileceği ve bu sistemlerin karmaşıklığından soyutlanarak tasarım yapılmasına olanak sağlayabileceği söylenebilir. Sabit kanatlı bir İHA bağlamında MBSE, İHA sisteminin çeşitli yönlerinin, gereksinimlerinin, mimarisinin, modeller aracılığıyla oluşturulmasına olanak vermektedir.

Tez çalışması içerisinde, sabit kanatlı bir İHA için MBSE prensipleri kullanılarak yapılan modelleme, hem işlevsel hem de işlevsel olmayan gereksinimlerin ortaya konmasını içermektedir. Tüm bunlara istinaden, yapılan model için modelleme dili SysML v1.6 olarak tercih edilmiş, hava aracının modelleneceği dijital modelleme ortamı olarak ise hem ücretsiz olmasından dolayı hem de program geliştiricilerinin geliştirme topluluklarına bilgi desteği sağlıyor olmasından dolayı Eclipse Papyrus programında karar kılınmıştır.

2.2. Hava Aracı Modelinin Oluşturulması

Papyrus programı içerisinde öncelikle elektrikli hava aracı mimarisinin genel yapısı SysML dili kullanılarak oluşturulmuştur.

Sistem modellemesi esnasında sistem mühendisliğinin temel felsefesi olan sistemin basitleştirilmesinin yolu tüm sistemi alt sistemler ile ifade etmektir. Bunun için örnek model olarak oluşturulacak olan sabit kanatlı İHA sistemi anlaşılabilirliği sağlamak için alt sistemlere bölünmüştür. Tüm bu alt sistemler kendi içlerinde de çeşitli unsurlar barındırmaktadır. Örneğin güç sistemi içerisinde batarya ve güç modülü bulunmakta, itki sistemi içerisinde elektrik motoru, ESC ve pervane bulunmakta ve kontrol sistemi içerisinde ise kontrol yüzeyleri (elevatör, aileron, rudder), aktüatör ve aktüatör kontrolcüsü bulunmaktadır. SysML kullanılarak modellenen alt sistemler ve bu alt sistemlerin içlerinde barındırdığı unsurlar aşağıda belirtilmiştir:

- Güç Sistemi
 - Batarya
 - Güç Modülü
- İtki Sistemi
 - Elektrik Motoru
 - ESC
 - Pervane
- Kontrol Sistemi
 - Aktüatör Kontrolcüsü
 - Aktüatörler
 - Kontrol Yüzeyleri
- Uçuş Kontrol Sistemi
 - Uçuş Kontrolcüsü
 - Uçuş Kontrol Bilgisayarı
- Emniyet ve Alarm Sistemi
 - Buzzer
 - Arm Switch
- Sensörler
 - Manyetometre
 - GPS

- IMU Sensörü
- Barometre
- Hava Hızı Sensörü
- Ultrasonik Sensör
- Aviyonikler
 - Mikrofon
 - Telemetri
 - Radyo Kontrol Alıcısı
 - Kamera

MBSE ve SysML metodolojilerini etkin şekilde kullanmak için sistemin genel yapısı diyagramlar üzerinden ifade edilmektedir. SysML kullanıcıya bir sistemin farklı yönlerini ortaya koyan çeşitli diyagramlar sunmaktadır. Bu diyagramlar sistem modellemesinin çeşitli noktalarında ihtiyaç duyulması halinde kullanılmakta ve sistemin görüntüsünün daha kolay ve etkili bir şekilde ortaya konmasına yardımcı olmaktadır. Model içerisinde kullanılan diyagramlar aşağıdaki gibidir:


- Blok Tanım Diyagramları: Blok Tanım Diyagramları (BDD), sistemin hiyerarşik olarak ortaya konmasına izin vererek sistemin yapısını, bileşenlerini ve bunların ilişkilerinin tasvir edilmesine yardımcı olmaktadır.
- Gereksinim Diyagramları: Gereksinim Diyagramları (RD), temel olarak, sistem gereksinimlerini, bunların ilişkilerini ve kısıtlamalarını yakalamak ve yönetmek için kullanılır.
- İç Blok Diyagramları: İç Blok Diyagramları (IBD), bir sistem bloğunun iç yapısını ve etkileşimlerinin gösterilmesinde kullanılmaktadır.
- Kullanım Senaryonu Diyagramları: Kullanım Senaryosu Diyagramları (UCD), sistem içerisinde bulunan çeşitli aktörlerin ve kullanım senaryolarının ifade edilmesinde kullanılmaktadır.

Mimarinin oluşturulmasındaki ilk adım olan BDD diyagramları oluşturulmadan önce değer tiplerinin belirlenmesi gerekmiştir.

2.2.1. Fiziksel büyüklükler ve veri tipleri


Hava aracı mimarisi geliştirilirken, öncelikle sistem modellemesi yapılırken kullanılacak fiziksel büyüklükler tanımlanmış ve veri akışı esnasındaki değer tipleri kısımları yaratılmıştır.

İlk olarak, sistem modellemesi yapılırken kullanılacak fiziksel birimlerin hepsi (Sıcaklık, Voltaj, Ağırlık, İrtifa, vb.) sistem içerisinde tanımlanmıştır (Şekil 2.1).



Şekil 2.1. Fiziksel birimlerin tanımlanması

Mimari içerisinde kullanılacak fiziksel birimlerin tanımlanması önem arz etmektedir. Bunun nedeni bu fiziksel büyüklüklerin sistem içerisindeki unsurların birbirleri ile ilişkisini ortaya koyarken kullanılacak olan değer tipleri yaratırken kullanılıyor olmasıdır (Şekil.2.2)




Şekil 2.2. Pervane değer tipinde fiziksel birimlerin kullanılması


Sonrasında her bir sistem ve her sistemin alt sistemi için değer tiplerinin (Value Type) oluşturulmasına başlanmıştır. Bu değer tipleri itki sistemi, kontrol sistemi, emniyet ve alarm sistemi, uçuş kontrol sistemi, güç sistemi, sensörler ve aviyoniklerin her biri ve bu her bir sistemin alt sistemleri için (Örneğin güç sistemi için batarya, güç modülü vb.) oluşturulmaya başlanmıştır.

2.2.1.1.İtki sistemi değer tipleri

İtki sistemi içerisinde üç farklı bileşen vardır. Bunlar elektrik motoru, ESC ve pervanedir. Değer tipleri oluşturulurken ilk olarak elektrik motoru ile başlanmış ve elektrik motoru üzerindeki potansiyel veriler belirlenerek Integer veri tipi ve Real veri tipleri altında fiziksel birimleri ile birlikte ifade edilmişlerdir (Şekil 2.3, Şekil 2.4)




Şekil 2.3. Elektrik motoru Integer değer tipi




Şekil 2.4. Elektrik motoru Real değer tipleri

Bir sonraki adımda, ESC'nin değer tipleri oluşturulmuştur. Maksimum akım, maksimum voltaj, Sinyal Genişlik Modülasyon (PWM) frekansı gibi değer tipleri Integer veri tipinde (Şekil 2.5), sıcaklık, voltaj dalgalanması gibi değer tipleri ise Real veri tipinde (Şekil 2.6) tanımlanmıştır.




Şekil 2.5. ESC Integer değer tipleri



Şekil 2.6. ESC Real değer tipleri


İtki sisteminin değer tiplerinde son adımda pervaneye ait değer tipleri oluşturulmuştur. Buradaki değer tipleri RPM ve gürültü değerleri olup, birimleri Real veri tipindedir (Şekil 2.7).



Şekil 2.7. Pervane real değer tipleri


2.2.1.2.Kontrol sistemi değer tipleri

Hava aracının kontrol sisteminin unsurlarından biri olan kontrol yüzeylerine ait değer tipleri sapma açısı, aktüatör PWM sinyali, yüzey alanı ve trim offset olarak belirlenmiştir. Bunlardan sapma açısı ve aktüatör PWM sinyalinin birimi Integer veri tipi olarak, yüzey alanı ve trim offset'in birimleri ise Real olarak belirlenmiştir (Şekil 2.8).




Şekil 2.8. Kontrol yüzeyleri değer tipleri

Kontrol sisteminin diğer bir bileşeni olan aktüatörlerin değer tipleri aktüatör hızı, aktüatör ivmesi ve aktüatör açısı olarak belirlenmiş olup, birimleri aktüatör açısı için Real veri tipi, diğerleri için Integer tipi olarak belirlenmiştir (Şekil 2.9).




Şekil 2.9. Aktüatör değer tipleri

Bir sonraki adımda, kontrol sisteminin son elemanı olan aktüatör kontrolcüsü için değer tipleri oluşturulmuştur. Integer veri tipindeki değer tipleri kontrolör durumu ve kontrolör modu (Şekil 2.10), Real tipindeki değer tipleri ise kontrolör kazancı, kontrolör çıkışı, kontrolör pozisyon hatası, kontrolör ivme hatası ve kontrolör tepki süresi olarak belirlenmiştir (Şekil 2.11).




Şekil 2.10. Aktüatör kontrolcüsü Integer değer tipleri




Şekil 2.11. Aktüatör kontrolcüsü Real değer tipleri

2.2.1.3.Emniyet ve alarm sistemi değer tipleri

Emniyet ve alarm sistemi içerisinde diğerlerinden farklı olarak Integer, Real ve Boolean tiplerinde üç farklı tipte veri olabileceği ön görülmüştür. Integer veri tipine bağlı olarak Buzzer ses desibeli, Buzzer ses süresi ve Buzzer alarm seviyesi oluşturulmuş (Şekil 2.12), Boolean veri tipine bağlı olarak Arm switch pozisyonu oluşturulmuş ve Real tipine bağlı olarak Arm switch doğrulama zamanı ve Buzzer ses frekansı değer tipleri oluşturularak birimleri daha önce yaratılmış olan fiziksel büyüklüklerden seçilmiştir (Şekil 2.13).




Şekil 2.12. Emniyet ve alarm sistemi Integer değer tipleri



Şekil 2.13. Emniyet ve alarm sistemi Boolean ve Real değer tipleri


2.2.1.4. Uçuş kontrol sistemi değer tipleri

Referans mimari içerisinde bulunan uçuş kontrol sisteminin bileşenlerinden biri olan uçuş kontrolcüsünün verileri giriş voltajı, sistem durumu, sıcaklık ve işlemci (CPU) yükü olarak belirlenmiştir. Bu değer tipleri ilgili veri tipleri ile ilişkilendirilmiş ve Integer veri tipi altında giriş voltajı ve sistem durumu, Real tip altında ise sıcaklık ve CPU yükü oluşturulmuştur (Şekil 2.14).




Şekil 2.14. Uçuş kontrolcüsü Integer ve Real değer tipleri

Uçuş Kontrol Bilgisayarı (FCC) içerisinde kullanılabilecek veriler FCC giriş voltajı, FCC giriş akımı, CPU kullanımı, bellek kullanımı ve depolama kapasitesi olarak belirlenmiş ve Integer veri tipi altında birleştirilmiş (Şekil 2.15), sıcaklık ve güç tüketimi ise Real veri tipi altında birleştirilerek tüm bu veriler fiziksel büyüklükler ile ilişkilendirilerek değer tipleri oluşturulmuştur (Şekil 2.16).



Şekil 2.15. Uçuş kontrol bilgisayarı Integer değer tipleri




Şekil 2.16. Uçuş kontrol bilgisayarı Real değer tipleri


2.2.1.5. Güç sistemi değer tipleri

Hava aracı içerisinde motorlara ve diğer elektronik ekipmanlara gerekli gücü sağlamak için oluşturulmuş olan güç sisteminde kullanılabilecek değer tipleri batarya voltajı, batarya deşarj akımı, süre, batarya gücü, batarya ağırlığı ve batarya şarj akımı değişkenleri Integer veri tipinde (Şekil 2.17), batarya sıcaklığı, batarya verimi, Batarya

Şarj Durumu (SoC) ve Batarya Sağlık Durumu (SoH) ise Real veri tipinde oluşturulmuştur (Şekil 2.18).




Şekil 2.17. Batarya Integer değer tipleri




Şekil 2.18. Batarya Real değer tipleri

Güç sisteminin diğer bir ögesi olan ve bataryadan gelen gücün dağıtılmasında rol oynayan güç modülüne ait değişkenlerden giriş voltajı, güç modülü voltajı, maksimum akım, aşırı akım koruması, verimlilik, ağırlık değerleri Integer veri tipinde (Şekil 2.19), sıcaklık, voltaj dalgalanması, güç dağılımı ve yük düzenlemesi değerleri ise Real veri tipinde oluşturulmuştur (Şekil. 2.20).



Şekil 2.19. Güç modülü Integer değer tipleri




Şekil 2.20. Güç modülü Real değer tipleri


2.2.1.6. Sensörler değer tipleri

Bir sonraki adımda, referans mimari içerisinde kullanılacak sensörlere ait değişkenlerin birimleri seçilmiş ve her biri Integer, Real veya String tipleri ile ilişkilendirilmiştir. Buna göre, hava aracının Manyetik Yön, Hava Aracı Yaw Oranı, Hava Aracı Pitch Açısı, Hava Aracı Yaw Açısı ve Hava Aracı Roll Açısı değer tipleri

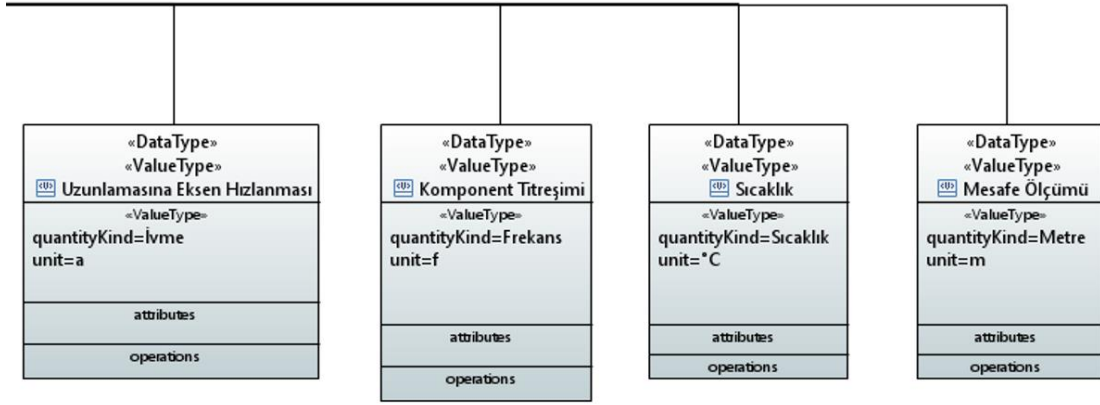
Integer veri tipi ile ilişkilendirilmiştir (Şekil 2.21). Hava aracı hızı, dinamik basınç, statik basınç, yanıl eksen hızlanması, dikey eksen hızlanması, uzunlamasına eksen hızlanması, komponent titreşimi, sıcaklık, mesafe ölçümü değır tipleri ise Real veri tipi ile ilişkilendirilmiştir (Şekil 2.22). Hava aracı irtifası, hava aracı enlemi, hava aracı boylamı ise String veri tipi ilişkilendirilmiştir (Şekil 2.23).




Şekil 2.21. Sensörler Integer değır tipleri



Şekil 2.22. Sensörler Real değır tipleri




Şekil 2.22. (Devam) Sensörler Real değer tipleri



Şekil 2.23. Sensörler String değer tipleri


2.2.1.7. Aviyonikler değer tipleri

Geliştirilmiş olan hava aracı mimarisinde değer tiplerinin yaratılmasındaki son adım olan aviyonikler kısmının oluşturulmasında ilk önce telemetri değer tipleri yaratılmış ve veri tipleri ile ilişkilendirilmiştir. Buna göre, sinyal kuvveti, veri oranı değer tipleri Integer veri tipi ile, sinyal kalitesi, gecikme ve bant genişliği değer tipleri ise Real veri tipi ile ilişkilendirilmiştir (Şekil 2.24).




Şekil 2.24. Telemetri değer tipleri

Bir sonraki adımda kamera ile ilgili değişkenler ele alınmıştır. Bu değer tiplerinin ifade edilmesinde kullanılacak veri tipleri Real tipi ve VideoData tipi olarak belirlenmiştir. SysML nesneye dayalı programlamayı da desteklediğinden dolayı veri tipleri klasik tiplerden farklı seçilebilmektedir. Buna bağlı olarak, kare hızı, zaman damgası ve çözünürlük değişkenleri VideoData tipinde, görüş alanı ve odak mesafesi ise Real veri tipinde oluşturulmuştur (Şekil 2.25).




Şekil 2.25. Kamera değer tipleri


Kamera ile ilgili deęer tipleri tanımlandıktan sonra radyo kontrol alıcısına ait deęişkenler tanımlanmış ve deęer tipleri oluşturularak fiziksel büyüklükler ile ilişkilendirilmiştir. Radyo kontrol alıcısına ait olarak belirlenmiş olan kanal sayısı, sinyal kuvveti ve sinyal kalitesi deęer tipleri Integer veri tipi ile (Şekil 2.26), bağlantı durumu boolean veri tipi ile ve alıcı voltajı Real veri tipi ile (Şekil 2.27), gaz kolu pozisyonu, elevatör pozisyonu, aileron pozisyonu, rudder pozisyonu ve arm switch pozisyon deęişkenleri ise RadyoControlSignal veri tipi ile ilişkilendirilmiştir (Şekil 2.28).



Şekil 2.26. Radyo kontrol alıcısı Integer deęer tipleri




Şekil 2.27. Radyo kontrol alıcısı Boolean ve Real değer tipleri



Şekil 2.28. Radyo kontrol alıcısı “Radyo Kontrol Sinyali” değer tipi

En son olarak, aviyonik ekipmanların son bileşeni olan mikrofona ilişkin değişkenleri tanımlanmış ve değer tipleri oluşturulmuştur. Mikrofon veri tipleri Integer ve Real olarak seçilmiştir. Buna göre, bit derinliği değer tipi Integer veri tipi ile, Ses verisi değer tipi ve örnekleme oranı değer tipi ise Real veri tipi ile ilişkilendirilmiştir (Şekil 2.29).



Şekil 2.29. Mikrofon değer tipleri


Tüm değer tiplerinin tanımlanmasından sonra hava aracının bloklar yardımı ile oluşturulmasına başlanmıştır. Bunun için ilk olarak tüm sistemin BDD diyagramları oluşturulmuş, sonrasında her bir alt sistem için sistem isterlerini belirten RD diyagramları oluşturulmuştur. Bir sonraki adımda sistemlerin birbirleri ile ilişkini detaylı olarak ortaya koyan IBD diyagramları oluşturulmuştur. En son ise sistemlerin kullanıcılar ve diğer sistemler ile etkileşimi gösteren UCD diyagramları oluşturulmuştur. Tüm çalışmalar ilgili başlıkların altında detaylı bir şekilde açıklanmıştır.

2.2.2. Blok tanım diyagramları

BDD diyagramlarının geliştirilmesine genel sistem mimarisi ile başlanmış ve öncelikle tüm hava aracı sistemine yukarıdan genel bir bakış sağlanmıştır.

2.2.2.1. Genel sistem mimarisi BDD

Genel sistem mimarisi güç sistemi, uçuş kontrol sistemi, kontrol sistemi, itki sistemi, emniyet ve alarm sistemi, sensörler, aviyonikler ile ilgili modeller ile BDD diyagramı şeklinde oluşturulmuş ve bu modellerin birbiri ile ilişkisi akan veriler üzerinden (pSys, fcSys, saSys, ctrlSys, dSys, drSys, sens, avionics) ortaya konmuştur (Şekil 2.30).




Şekil 2.30. Genel sistem mimarisi BDD diyagramı

Tüm sistemi ortaya koyan genel sistem mimarisine ait blok diyagram bittikten sonra, genel sistem mimarisinin alt sistemlerinin modellenmesi yapılmıştır.

2.2.2.2.İtki sistemi BDD

Alt sistemlerin önemli unsurlarından biri olan ve bu çalışma içerisinde de diyagnostik bağlamda değerlendirilen motor ve pervane kısımlarının olduğu itki sisteminin BDD diyagramı ilk olarak oluşturulmuştur. IBD diyagramları oluşturulurken itki sistemi içerisinde dışarıya olacak bağlantılar motor için “elecM”, hız kontrolcüsü için “esc” ve pervane için ise “prop” olarak belirlenmiştir (Şekil 2.31).




Şekil 2.31. İtki Sistemi BDD diyagramı

İtki sisteminin BDD diyagramı bittikten sonra kontrol sisteminin diyagramı oluşturulmuştur.

2.2.2.3.Kontrol sistemi BDD


Alt sistemlerden biri olan kontrol sisteminin BDD diyagramını oluştururken aynı isimli bir paket oluşturulmuş ve bu sisteme bağlı olacak olan bloklar Aktüatör Kontrolcüsü, Elevatör, Rudder, Aileron, Elevatör Aktüatör, Rudder Aktüatör ve Aileron Aktüatör olarak belirlenmiştir. Bu blokların birbirleri ile olan ilişkisi diagram üzerinde açıklanmış ve akacak olan veriler ortaya konmuştur (Şekil 2.32).



Şekil 2.32. Kontrol sistemi BDD diyagramı

2.2.2.4.Emniyet ve alarm sistemi BDD


Kontrol sistemine ait BDD diyagramı oluşturulduktan sonra, Emniyet ve Alarm sisteminin BDD diyagramı oluşturulmuş ve bu sistemin alt elemanları olan Buzzer ve Arm Switch ile olan ilişkisi ve akan veriler modellenmiştir (Şekil 2.33).



Şekil 2.33. Emniyet ve alarm sistemi BDD diyagramı

2.2.2.5.Uçuş kontrol sistemi BDD


Emniyet ve alarm sisteminin BDD diyagramı oluşturulduktan sonra bir başka alt sistem olan uçuş kontrol sistemi için BDD diyagramı oluşturulmuştur. Uçuş kontrol sistemi oluşturulurken uçuş kontrolcüsü ve uçuş kontrol bilgisayarı blokları bu sisteme bağlı olarak oluşturulmuştur. Aynı sistem içerisinde uçuş kontrolcüsü ve uçuş kontrol bilgisayarı birlikte kullanılabilir. Özellikle gerçek zamanlı görüntü işleme, tanı-teşhis gibi uygulamalar esnasında geleneksel bir uçuş kontrolcüsünün veri işleme yetenekleri zayıf kaldığından ötürü, bu tip yoğun veri işlemlerinin yapılması için sistem üzerinde uçuş kontrolcüsü vasıtası ile sensör ve diğer uçuş verilerine ulaşabilen ve bu veriler ile işlem yapabilen Raspberry Pi gibi bir uçuş bilgisayarı kullanılabilir. Bu durum gözetilerek geliştirilen model içerisinde bu yapı benimsenmiştir. Uçuş kontrolcüsü ve uçuş kontrol bilgisayarı birbirleri ile olan ilişkileri ve akacak olan muhtemel veriler ortaya konmuştur (Şekil 2.34).



Şekil 2.34. Uçuş kontrol sistemi BDD diyagramı

2.2.2.6.Güç sistemi BDD


Bir sonraki adımda içerisinde batarya ve güç modülü bulunan güç sistemine ait BDD diyagramı oluşturularak bu bloklar ile ilişkili veriler gösterilmiştir (Şekil 2.35).



Şekil 2.35. Güç sistemi BDD diyagramı

2.2.2.7.Sensörler BDD


Güç sisteminin BDD diyagramı tamamlandıktan sonra, bir sonraki adımda referans hava aracı mimarisi için kullanılabilecek örnek sensörleri içeren BDD diyagramı oluşturulmuştur. Bu BDD diyagramı sensörleri bir arada ifade edebilmek ve “Sensörler” başlıklı bloktan tüm sistem ile ilişkilendirilen verileri (mgntmSens, gpsSens, imuSens, baromSens, havaHızıSens, ultsnkSens) göstermektedir (Şekil 2.36).



Şekil 2.36. Sensörler BDD diyagramı

2.2.2.8.Aviyonikler BDD

Diğer bir önemli BDD diyagramı ise aviyonikler bloğudur. Bu diyagram, içerisinde hava aracına ait sistem mühendisliği modeli referans alınarak kullanılabilecek örnek aviyonik bileşenler bulunmaktadır. Tez çalışmasının ileri kısımlarında gerçekleştirilen diyagnostik çalışmada geliştirilmiş olan referans mimarinin aviyonik BDD diyagramı içerisinde bulunan mikrofon bloğu esas alınmıştır. Aviyonik BDD diyagramının geliştirilmesi ile ilgili çalışma Şekil 2.37’de gösterilmiştir.




Şekil 2.37. Aviyonikler BDD diyagramı

2.2.3. Gereksinim diyagramları


Hava aracına ait BDD diyagramlarının modellenmesi bittikten sonra, ilgili mimarinin bütün bir şekilde ortaya konabilmesi amacıyla her bir sistem ve alt sistemin gereksinimleri belirlenmiş ve SysML dili kullanılarak RD diyagramları modellenmiştir. Bu gereksinimler ortaya konarak modellenirken yapısal (Structural), yapısal olmayanlar (Non Structural), Fonksiyonel (Functional) ve Fonksiyonel olmayanlar (Non Fuctional) olarak temelde dört başlık altında oluşturulmuştur. Yapısal gereksinimler performans ve emniyet gibi gereksinimlerden oluşmakta, yapısal olmayan gereksinimler ağırlık ve maliyet gibi unsurlardan oluşmakta, fonksiyonel gereksinimler ise ilgili parça veya ekipmanın çalışmasına etki edecek gereksinimlerden oluşmaktadır.

2.2.3.1.İtke sistemi RD

Geliştirilmiş olan itki sistemi BDD diyagramında, itki sistemi içerisinde bulunacak bileşenler elektrik motor, ESC ve pervane olarak belirlenmiştir. İlk olarak bu bileşenlerden bir tanesi olan elektrik motoru için RD oluşturulmuştur. İlgili diyagram içerisinde bulunan yapısal gereksinimler kısmında (Şekil 2.38) termal koruma, soğutma, RPM gibi unsurlar yer almakta, yapısal olmayan gereksinimler kısmında ise (Şekil 2.39) motor maliyeti bulunmaktadır.



Şekil 2.38. Motorun yapısal gereksinimler




Şekil 2.39. Motorun yapısal olmayan gereksinimleri

Sonraki adımda, itki sisteminin bir diğer unsuru olan ESC'ye ait RD diyagramı oluşturulmuştur (EK-1a, EK-1b, EK-1c, EK-1d, EK-1e, EK-1f). Bu RD diyagramının içerisinde giriş-çıkış voltajı, termal yönetim, elektriksel koruma, ağırlık ve boyut gibi ESC'nin performansını ve kullanımını etkileyecek özellikler belirtilmiştir.


Geliştirilmiş olan referans mimaride, itki sisteminin son ekipmanı pervanedir. Pervane RD diyagramı öncelikli olarak yapısal ve yapısal olmayan gereksinimlerden oluşmaktadır. Yapısal gereksinimlerin içerisinde materyal dayanımı, denge ve titreşim, yapısal sağlamlık gibi başlıklar bulunmakla birlikte, örneğin yapısal sağlamlık başlığının

altında deformasyon, çatlak ve tükenmişlik (fatigue) gibi pervaneyi yapısal olarak etkileyebilecek durumlar ve bunların açıklamaları yer almaktadır (Şekil 2.40).




Şekil 2.40. Pervanenin yapısal gereksinimleri

Yapısal olmayan gereksinimler kısmında ise pervaneye ait aerodinamik verimlilik, performans, emniyet ve çevresel etkiler ile ilgili gereksinimler bulunmaktadır (Şekil 2.41).




Şekil 2.41. Pervanenin yapısal olmayan gereksinimleri



Şekil 2.41. (Devam) Pervanenin yapısal olmayan gereksinimleri


2.2.3.2. Kontrol sistemi RD

Hava aracının kontrol yüzeyleri ve bu yüzeylerle ilişkili olan kısımların bulunduğu kontrol sistemin unsurlarından biri olan kontrol yüzeylerine ait RD diyagramı mekaniksel sağlamlık, boyut, hareket sınırları, aerodinamik performans, maksimum sapma açısı gibi gereksinimler barındırmaktadır. Kontrol yüzeylerinden aileron'a ait gereksinimlerden yapısal gereksinimler Şekil 2.42'de belirtilmiştir.




Şekil 2.42. Aileron'un yapısal gereksinimleri

Aileron'a ait operasyonel limitler, hareket sınırlamaları, diferansiyel sapma gibi fonksiyonel gereksinimlerden bazıları ise Şekil 2.43'de belirtilmiştir.




Şekil 2.43. Aileron'un fonksiyonel gereksinimleri




Şekil 2.43. (Devam) Aileron'un fonksiyonel gereksinimleri

Kontrol sisteminin diğer bir unsuru olan aktüatör, kontrol sinyali uyumluluğu, tepki süresi, kuvvet ve tork gibi gereksinimlerden oluşmaktadır. Bu gereksinimlerden yapısal gereksinimler Şekil 2.44'de belirtilmiştir. Fonksiyonel gereksinimlerden bazıları ise Şekil 2.45'de yer almaktadır.

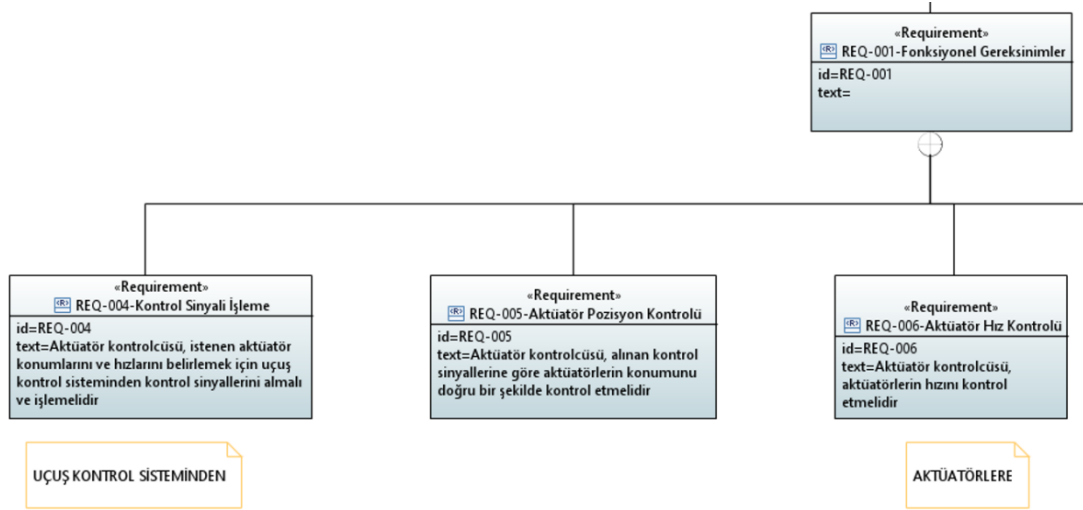


Şekil 2.44. Aktüatörün yapısal gereksinimleri




Şekil 2.45. Aktüatörün fonksiyonel gereksinimleri


Kontrol sisteminin son unsuru olan aktüatör kontrolcüsü ise, hız kontrolü, senkronizasyon ve pozisyon kontrolü gibi fonksiyonel gereksinimlerden (Şekil 2.46), yedeklilik, emniyetli operasyon gibi emniyet gereksinimlerinden (Şekil 2.47) ve tepkisellik, doğruluk, güvenilebilirlik gibi performans gereksinimlerinden (Şekil 2.48) oluşmaktadır.



Şekil 2.46. Aktüatör kontrolcüsünün fonksiyonel gereksinimleri




Şekil 2.47. Aktüatör kontrolcüsünün emniyet gereksinimleri



Şekil 2.48. Aktüatör kontrolcüsünün performans gereksinimleri


2.2.3.3.Emniyet ve alarm sistemi RD

Referans mimari içerisinde yer alan ve BDD diyagramları içerisinde de belirtilen diğer bir alt sistem emniyet ve alarm sistemidir. İlk önce bu sisteme ait unsurlardan biri olan Buzzer ile ilgili gereksinimler oluşturulmuştur. Oluşturulan RD diyagramı yapısal, yapısal olmayan ve fonksiyonel olmak üzere üç başlık altında oluşturulmuştur. Yapısal gereksinimler başlığı altında uçuş kontrolcüsü ile entegrasyon vardır. Fonksiyonel gereksinimler içerisinde ise sistemin kritik durumları veya uyarıları için ses yayması ve sistem ile ilgili bilgilerin ses ile ayırt edilebilmesi özellikleri yer almaktadır (Şekil 2.49).



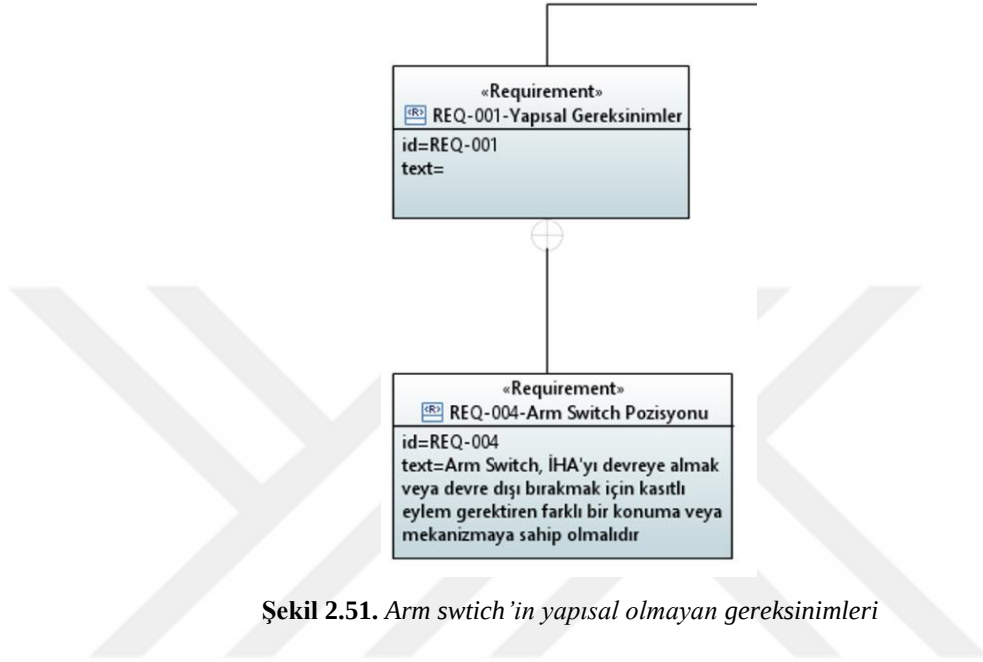
Şekil 2.49. Buzzer'ın yapısal ve fonksiyonel gereksinimleri

Diğer kategorize edilmiş gereksinim olan yapısal olmayan gereksinimler altında ise ses kontrolü, frekans kontrolü ve hata tespiti vardır (Şekil 2.50)




Şekil 2.50. Buzzer'ın yapısal olmayan gereksinimleri


Emniyet ve alarm sisteminin diğ er elemanı olan Arm Switch ise, yapısal gereksinimler olarak Arm pozisyonu ( ekil 2.51), fonksiyonel gereksinimler olarak emniyet kilidi ve arm durumu gibi gereksinimlerden ( ekil 2.52) ve yapısal olmayan gereksinimler olarak ise g rsel indikat r'den olu maktadır ( ekil 2.53).



 ekil 2.51. Arm switch'in yapısal olmayan gereksinimleri



Şekil 2.52. Arm Switch'in fonksiyonel gereksinimleri




Şekil 2.53. Arm switch 'in fonksiyonel olmayan gereksinimleri


2.2.3.4. Uçuş kontrol sistemi RD

Geliştirilmiş olan hava aracı mimarisinin önemli unsurlarından biri uçuş kontrol sistemidir. Uçuş kontrol sisteminin unsurlarından biri olan uçuş kontrolcüsü, konnektör uyumluluğu, boyut ve ağırlık, sağlamlık gibi yapısal gereksinimlerden (EK-2a), kontrol sinyali işleme, uçuş kontrol modu, sensör füzyonu, iletişim gibi fonksiyonel gereksinimlerden (EK-2b, EK-2c) ve işlem gücü, güç temini, yazılımın güncellenebilmesi gibi fonksiyonel olmayan gereksinimlerden (EK-2d, EK-2e) oluşmaktadır.


Uçuş kontrol sistemi'nin diğer bir unsuru olan uçuş kontrol bilgisayarı ise, uçuş kontrolcüsü ile uyum, modülerlik ve genişletilebilirlik gibi yapısal gereksinimlerden (Şekil 2.54), sensör arayüzü, gerçek zamanlı veri işleme, yazılımla uyumluluk gibi fonksiyonel gereksinimlerden (Şekil 2.55) ve emniyet, güç verimliliği gibi yapısal olmayan gereksinimlerden (Şekil 2.56) oluşmaktadır.




Şekil 2.54. Uçuş kontrol bilgisayarının yapısal gereksinimleri



Şekil 2.55. Uçuş kontrol bilgisayarının fonksiyonel gereksinimleri



Şekil 2.55. (Devam) Uçuş kontrol bilgisayarının fonksiyonel gereksinimleri




Şekil 2.56. Uçuş kontrol bilgisayarının yapısal olmayan gereksinimleri


2.2.3.5.Güç sistemi RD

Bir sonraki adımda, hava aracının emniyetli ve yüksek performans ile uçurulmasında önemli bir yeri olan güç sisteminin RD diyagramı yapılmıştır. Güç sistemi, içerisinde batarya ve güç modülünü barındırmaktadır. Batarya modülü Performans ve Emniyet başlıklarından oluşan yapısal gereksinimler (Şekil 2.57) ve ağırlık ve maliyet başlıklarından oluşan yapısal olmayan gereksinimlerden oluşmaktadır (Şekil 2.58).





Şekil 2.57. Bataryanın yapısal gereksinimleri



Şekil 2.58. Bataryanın yapısal olmayan gereksinimleri


Güç modülü kısmı ise voltaj aralığı, güç verimliliği, sıcaklık aralığı, yedeklilik ve hata toleransı gibi gereksinimlerden oluşmaktadır (Şekil 2.59).

2.2.3.6.Sensörler RD


Güç sistemi ile ilgili RD diyagramları bittikten sonra, referans olarak oluşturulan hava aracı mimarisi içerisinde yer alabilecek bazı örnek sensörleri içeren Sensörler kısmının RD diyagramı yapılmıştır. Sensörler kısmı IMU, GPS, barometre, manyetometre, hava hızı ve ultrasonik sensör takımlarından oluşmaktadır.

Örnek olarak belirlenmiş sensörlerden biri olan IMU sensörü, doğruluk ve örnekleme hızı gibi performans gereksinimlerinden, uyumluluk ve yerleştirme gibi entegrasyon gereksinimlerinden, sıcaklık aralığı ve titreşime karşı dayanıklılık gibi çevresel gereksinimlerinden, kalibrasyon ve sağlamlık ve güvenilebilirlik gereksinimlerinden oluşmaktadır (Şekil 2.60).






Şekil 2.60. IMU gereksinimleri




Şekil 2.60. (Devam) IMU gereksinimleri

Diğer bir sensör olan ve sistem mimarisi içerisinde yer verilen sensör Barometre'dir. Sensörün RD diyagramı temel olarak yapısal ve fonksiyonel gereksinimlerden oluşmaktadır. Yapısal gereksinimlerin içerisinde güvenilebilirlik, arayüz uyumluluğu ve çevresel etmenlerden korunma ana başlıkları vardır (Şekil 2.61). Fonksiyonel gereksinimler ise, irtifa ölçüm doğruluğu, basınç ölçüm aralığı, sıcaklık dayanıklılığı, veri güncelleme hızı ve kalibrasyon başlıklarından oluşmaktadır (Şekil 2.62).






Şekil 2.61. Barometrenin yapısal gereksinimleri




Şekil 2.61. (Devam) Barometrenin yapısal gereksinimleri




Şekil 2.62. Barometrenin fonksiyonel gereksinimleri


Bir diğ er sensor olan GPS sens  r   Yapısal, Fonksiyonel ve Yapısal olmayan gereksinimlerden oluřmaktadır. Yapısal gereksinimler i erisinde  evresel uyumluluk (řekil 2.63), fonksiyonel gereksinimler i erisinde pozisyon dođruluđu, sinyal alma ve izleme, yenileme hızı, entegrasyon ve uyumluluk gibi bařlıklar (řekil 2.64) ve yapısal olmayan gereksinimler i erisinde ise g  c t  ketimi vardır (řekil 2.65).




řekil 2.63. GPS'in yapısal gereksinimleri



Şekil 2.64. GPS'in fonksiyonel gereksinimleri




Şekil 2.64. (Devam) GPS'in fonksiyonel gereksinimleri




Şekil 2.65. GPS'in yapısal olmayan gereksinimleri


Manyetometre sensörü ise, manyetik alan ölçümleri, hassasiyet, kalibrasyon, çalışma sıcaklık aralığı, Elektromanyetik/Radyo Frekans Parazit (EMI/RFI) dayanıklılığı gibi gereksinimlerden oluşmaktadır. Bu gereksinimler Yapısal Gereksinimler (Şekil 2.66), Fonksiyonel Gereksinimler (Şekil 2.67) ve Fonksiyonel Olmayan Gereksinimler (Şekil 2.68) olarak oluşturulmuştur.



Şekil 2.66. Manyetometrenin yapısal gereksinimleri




Şekil 2.67. Manyetometrenin fonksiyonel gereksinimleri




Şekil 2.68. Manyetometrenin fonksiyonel olmayan gereksinimleri


Hava hızı ölçüm sensörü, Yapısal, Fonksiyonel ve Fonksiyonel Olmayan gereksinimler başlıklarında toplanmıştır. Bunlardan yapısal gereksinimler, içerisinde entegrasyon ve birleştirme başlığını içermekte (Şekil 2.69), fonksiyonel gereksinimler, hava hızı ölçümü, mesafe, hassaslık doğruluk, tepki süresi ve veri çıkışı başlıklarını içermekte (Şekil 2.70), fonksiyonel olmayan gereksinimler ise çalışma sıcaklık aralığı, güç tüketimi ve EMI/RFI dayanıklılığı başlıklarından oluşmaktadır (Şekil 2.71).



Şekil 2.69. Hava hızı sensörünün yapısal gereksinimleri




Şekil 2.70. Hava hızı sensörünün fonksiyonel gereksinimleri

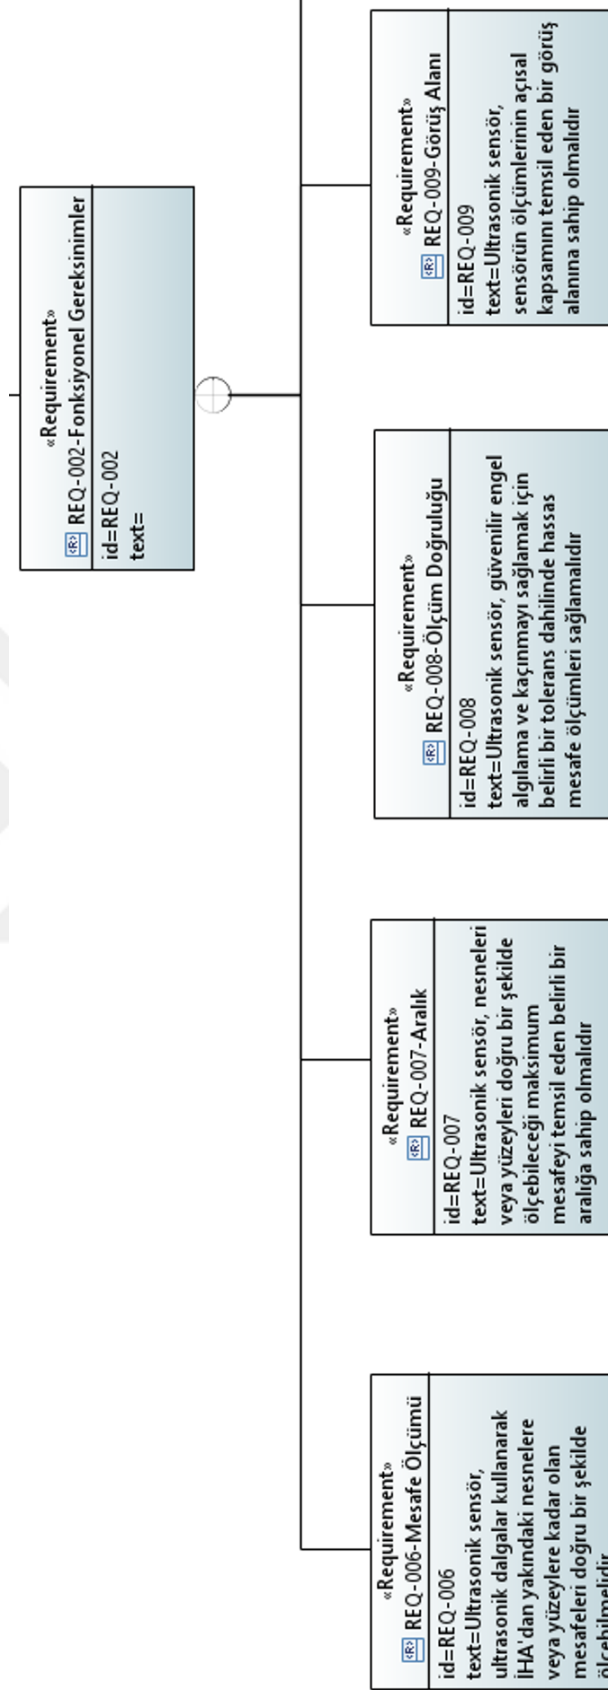


Şekil 2.71. Hava hızı sensörünün fonksiyonel olmayan gereksinimleri


Mesafe ölçümlerinde kullanılan bir sensör olan ultrasonik sensör ise, örnekleme oranı, görüş alanı, mesafe, çalışma frekansı ve sağlamlık gibi başlıklardan ve yapısal (Şekil 2.72), fonksiyonel (Şekil 2.73) ve fonksiyonel olmayan (Şekil 2.74) gereksinimlerden oluşmaktadır.




Şekil 2.72. Ultrasonik sensörün yapısal gereksinimleri



Şekil 2.73. Ultrasonik sensörün fonksiyonel gereksinimleri




Şekil 2.73. (Devam) Ultrasonik sensörün fonksiyonel gereksinimleri




Şekil 2.74. Ultrasonik sensörün fonksiyonel olmayan gereksinimleri

2.2.3.7. Aviyonikler RD


Aviyonik ekipmanlar kısmının unsurlarından biri olan telemetri modülü, veri güvenliği, parazit azaltımı, boyut ve ağırlık gibi gereksinimlerden oluşmaktadır. Buradaki tüm gereksinimler yapısal (Şekil 2.75), yapısal olmayan (Şekil 2.76), fonksiyonel (Şekil 2.77) ve fonksiyonel olmayan (Şekil 2.78) gereksinimler olarak sınıflandırılmışlardır.



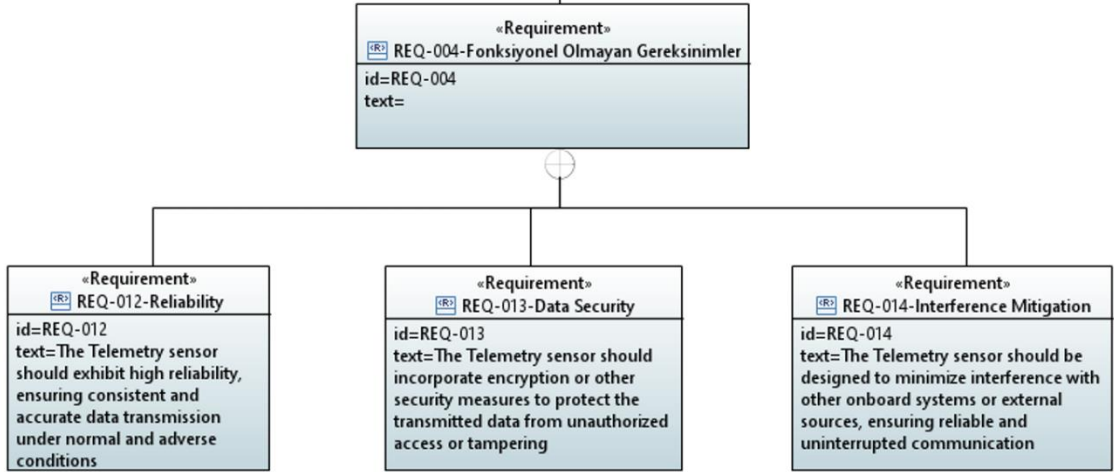
Şekil 2.75. Telemetrinin yapısal gereksinimleri



Şekil 2.76. Telemetrinin yapısal olmayan gereksinimleri




Şekil 2.77. Telemetrinin fonksiyonel gereksinimleri




Şekil 2.78. Telemetrinin fonksiyonel olmayan gereksinimleri

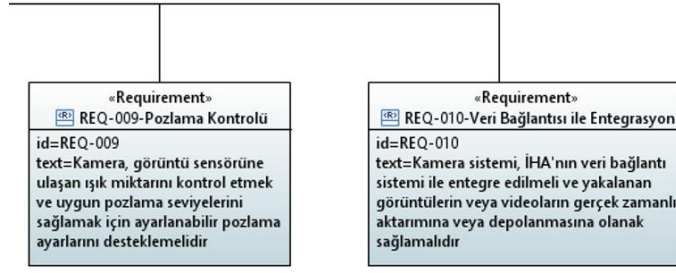
Diğer bir aviyonik ekipman olan kamera, güç kaynağı, çevresel koruma gibi yapısal gereksinimlerden (Şekil 2.79), görüntü yakalama, odaklanma kontrolü, poz kontrolü gibi fonksiyonel gereksinimlerden (Şekil 2.80) ve görüntü kalitesi, uyumluluk, güvenilirlik gibi yapısal olmayan gereksinimlerden oluşmaktadır (Şekil 2.81).




Şekil 2.79. Kameranın yapısal gereksinimleri



Şekil 2.80. Kameranin fonksiyonel gereksinimleri




Şekil 2.80. (Devam) Kameranın fonksiyonel gereksinimleri




Şekil 2.81. Kameranın fonksiyonel olmayan gereksinimleri


Aviyonik ekipmanların bir diğeri olan radyo kontrol alıcısı, radyo sinyal alımı, kanallar ve uyumluluk, sinyal kalitesi, sağlamlık gibi başlıklardan ve yapısal (Şekil 2.82), fonksiyonel (Şekil 2.83) ve yapısal olmayan (Şekil 2.84) gereksinimlerden oluşmaktadır.




Şekil 2.82. Radyo kontrol alıcısının yapısal gereksinimleri



Şekil 2.83. Radyo kontrol alıcısının fonksiyonel gereksinimleri




Şekil 2.83. (Devam) Radyo kontrol alıcısının fonksiyonel gereksinimleri



Şekil 2.84. Radyo kontrol alıcısının fonksiyonel olmayan gereksinimleri

Aviyonik ekipmanların sonuncusu olan ve tez çalışması içerisinde de faydalanılan mikrofonun RD diyagramı, yapısal ve yapısal olmayan olmak üzere iki ana grupta oluşturulmuş olup, örnekleme miktarı, yön ve gürültü engelleme gibi gereksinimlerden oluşmaktadır (Şekil 2.85).



Şekil 2.85. Mikrofon RD diyagramı

Tüm BDD ve RD diyagramlarının oluşturulması bittikten sonra sistemin IBD diyagramları oluşturulmuş ve genel sistem mimarisi (Şekil 2.30) üzerinde bulunan tüm alt sistemlerin (Güç Sistemi, Kontrol Sistemi, Uçuş Kontrol Sistemi, İtki Sistemi, Emniyet ve Alarm Sistemi, Sensörler ve Aviyonikler) birbirleri ile haberleşmesi ele alınmıştır.

2.2.4. İç blok diyagramları

Alt sistemlerin genel görünümünü ifade eden BDD diyagramlar ve sistem içerisinde bulunan ekipman ve teçhizatın gereksinimlerini belirten RD diyagramları bittikten sonra, BDD diyagramlarında ifade edilen sistemlerin iç yapılarını gösteren IBD diyagramlarının oluşturulmasına devam edilmiştir. IBD'ler, MBSE'de kullanılan SysML'in temel bir bileşenidir. Bu diyagramlar, birbirine bağlı bileşenleri ve bunların etkileşimlerini göstererek bir sistemin iç yapısının grafiksel gösterimler ile net bir şekilde ortaya konmasını sağlar ve özellikle bir sistemin bileşenlerini, sistemin iç bloklarını, bağlantı noktalarını ve bunlar arasındaki bilgi veya sinyal akışını göstermeyi amaçlamaktadır. Ayrıca, IBD'ler sistem karmaşıklığının üstesinden gelinebilmesi adına sistemlerin yönetilebilir alt sistemlere veya bileşenlere ayrıştırılmasını da sağlamaktadır. IBD ile kurulan bu yapı, sistemin giderek daha ayrıntılı bloklara bölündüğü ve sistem tasarımı ve analizine yukarıdan aşağıya bir yaklaşım sağlayarak sistemin iç işleyişinin daha ayrıntılı bir şekilde anlaşılmasını sağlamaktadır. Tez çalışması içerisinde ele alınan sistem IBD diyagramları aşağıdaki gibidir.

2.2.4.1. Genel sistem mimarisi IBD

Genel sistem mimarisi IBD diyagramı, uçuş kontrol sistemi olarak nitelendirilen, içerisinde bir uçuş kontrolcüsü ve bir uçuş kontrol bilgisayarını barındıran ve tüm sistemdeki veri akışlarının üzerinde toplandığı ve dağıtıldığı kısımdır. Tez çalışması içerisinde, bu kısımda gerekli tüm bağlantı noktaları oluşturulmuş ve sistem içerisindeki her bir bileşenden gelen verilerin sistemin bütününe nasıl dağıtıldığı diyagram olarak ortaya konulmuştur. Bu mimari oldukça büyük olduğundan ötürü parçalı şekilde gösterilmiştir. (EK-3a, EK-3b, EK-3c, EK-3d, EK-3e, EK-3f).

Genel sistem mimarisi, sistemi yukarıdan gösteren en kapsamlı IBD diagramı olup, Güç Sistemi, Kontrol Sistemi, Uçuş Kontrol Sistemi, İtki Sistemi, Emniyet ve Alarm Sistemi, Aviyonikler ve Sensörlerin tümünden gelen veri akışını ortaya koymaktadır.

Bir sonraki adımda, genel sistem mimarisi içerisinde gösterilen her bir alt sistemin kendi IBD diyagramları ayrıca oluşturulmuştur.

2.2.4.2.İtki sistemi IBD


Hava aracı mimarisinin ilk başlangıç noktası olan BDD diyagramları oluşturulurken de belirtildiği üzere hava aracı itkisinin üretildiği tarafı temsil eden itki sisteminin içerisinde ESC, motor ve pervane bileşenleri bulunmaktadır. IBD diyagramları geliştirilirken ilk olarak bu sisteme ait IBD diyagramı tamamlanmış olup, ilgili diyagram içerisindeki bileşenlerin hangi verilere ihtiyaç duyduğunu ve sistem akışını göstermektedir (EK-4).

2.2.4.3.Kontrol sistemi IBD

Hava aracı içerisindeki kontrol yüzeyleri, kontrol yüzeylerini hareket ettiren aktüatörleri ve bu aktüatörlere kontrol sinyali sağlayan aktüatör kontrolcülerini içeren alt sistem kontrol sistemidir. Bu diyagram içerisinde uçuş kontrol sisteminden gelen ve rudder, elevatör, aileron yüzeylerinin hareketlerini sağlayan veri akışları, hareket sonrasında oluşturulan geri bildirimler, pozisyon hataları bu IBD diyagramı içerisinde gösterilmiştir (EK-5).

2.2.4.4.Emniyet ve alarm sistemi IBD

Emniyet ve Alarm sistemi IBD diyagramı içerisinde hava aracının motorlarının aktif veya deaktif konuma getirilmesini ve böylelikle uçuş kontrol sisteminin devreye alınıp alınmayacağını kontrolünün sağlanmasında kullanılan “Arm Switch” anahtarı ve hava aracı ile ilgili ikazları sesli olarak belirten “Buzzer” bileşenleri bulunmaktadır. Emniyet ve alarm alt sistemi içerisinde değerlendirilen bu bileşenler ile ilgili gelen Arm Switch pozisyonu ve Buzzer alarm seviyesi bilgilerinin akışları emniyet ve alarm sistemi IBD diyagramı içerisinde gösterilmektedir (Şekil 2.86).



Şekil 2.86. Emniyet ve alarm sistemi IBD


2.2.4.5. Uçuş kontrol sistemi IBD

Genel sistem mimarisi IBD diyagramı (EK-3a, EK-3b, EK-3c, EK-3d, EK-3e, EK-3f) içerisinde de görülebileceği üzere tüm sistemin en karmaşık IBD diyagramlarından bir tanesi uçuş kontrol sistemi IBD diyagramıdır (EK-6a, EK-6b, EK-6c, EK-6d). Uçuş kontrol sistemi kısmı hava aracının sorunsuz şekilde uçmasını sağlayan asgari ekipmanlardan biri olan uçuş kontrolcüsü ve daha yüksek bilgi işlem gücüne sahip olan ve ihtiyaca göre opsiyonel olarak kullanılabilecek bir FCC'den oluşmaktadır. Uçuş kontrolcüsü genel olarak sensörler ve aviyonikler kısmından gelen hayati verileri (hız, sıcaklık, irtifa, hızlanma, yön, basınç, radyo sinyali vb.) işleyerek hava aracının idame edilmesini sağlarken, FCC ise daha yüksek işlem gücü gerektiren görüntüleme veya pervane, motor ve batarya kısımlarının diagnostik uygulamalarında kullanılabilir. Uçuş kontrol sistemi için oluşturulmuş olan IBD diyagramı içerisinde sistem üzerinde akabilecek tüm veriler gösterilmiştir.

Uçuş kontrol sistemi veya diğer tüm IBD diyagramlarının her birinden çıkan verilerin hava aracı sisteminin tam olarak neresine ulaştığı bilgisi genel sistem mimarisi IBD diyagramı içerisinde kolaylıkla görülebilir.

2.2.4.6. Güç sistemi IBD

Hava aracının IBD diyagramlarından bir diğeri güç sistemi IBD diyagramıdır. Güç sistemi içerisinde hava aracının motorlarına ve diğer aviyonik bileşenlerine yeterli gücü sağlamakla sorumlu batarya ve isterlere bağlı olarak bu gücün sistemin ne tarafına nasıl dağıtılması gerektiğini yöneten güç modülü bileşenleri yer almaktadır (Şekil 2.87).




Şekil 2.87. Güç sistemi IBD diyagramı

2.2.4.7.Sensörler IBD

Hava aracında potasiyel olarak kullanılabilecek sensörlerin ve bu sensörlerin diğer sistemler ile haberleşmesinin gösterildiği IBD diyagramı, manyetik yön bilgisini sağlayan manyetometre, irtifa, üç eksen de dönüş açıları (Pitch, Roll, Yaw) ve üç eksen deki (Yatay, Dikey, Uzunlamasına) hızlanma verilerini sağlayan IMU, statik basınç bilgisini sağlayan barometre ve mesafe bilgisini sağlayan ultrasonik sensör bileşenlerinden oluşmaktadır. Sistem içerisinde diğer sistemlere sağlanan veri akışları sensörler IBD diyagramı içerisinde gösterilmiştir (EK-7a, EK-7b).

2.2.4.8.Aviyonikler IBD

Aviyonikler IBD diyagramı içerisinde, hava aracında bulunabilecek çeşitli elektronik ekipmanların ilişkileri belirtilmektedir. Bu elektronik ekipmanlar radyo kontrol alıcısı, kamera, telemetri ve mikrofon olarak örneklendirilmiştir. Telemetri modülü içerisinde, sensör kısımlarından gelen veriler ve uçuş kontrol sistemi tarafından yönlendirilmiş sinyaller bulunmaktadır. Mikrofon ve kamera modülleri elde ettikleri verileri işlenmesi için uçuş kontrol sistemi kısmına göndermekte ve radyo kontrol alıcısı kısmı ise bir yandan operatör tarafından gelen radyo kontrol sinyallerini uçuş kontrol sistemine iletmekte ve diğer yandan ise sinyal kalitesi bilgisini operatör tarafına göndermektedir. Bu elektronik ekipmanların veri akışlarını içeren diyagram aviyonikler IBD diyagramıdır (Şekil 2.88).



Şekil 2.88. Aviyonikler IBD diyagramı

Oluşturulan IBD diyagramlarının elektrikli hava aracı mimarisi bağlamında önemleri şu şekilde açıklanabilir:

- Bileşenlerin Görselleştirilmesi: IBD diyagramları sistem içerisindeki sensörler, aktüatörler, uçuş bilgisayarları gibi bileşenleri, bu bileşenlerin birbirleri ile bağlantılarını ve hava aracının sistem içi etkileşimlerini görselleştirerek sistemin nasıl çalıştığının anlaşılmasını sağlamaktadır.
- Alt Sistem Bağlantılarının Detaylandırılması: Hava aracı içerisindeki farklı sistemlerin (Güç sistemi, aviyonikler, uçuş kontrol sistemi vb.) hava aracı içerisinde nasıl birbirlerine bağlandığını detaylandırmaktadır.

- **Veri Akışı:** IBD diyagramları, farklı bileşenler arasındaki veri veya sinyal akış durumlarını göstererek hangi sistemin ne gibi bilgilere ihtiyacı olduğunu ve hangi sistemin hangi verileri sağladığını anlamaya yardımcı olmaktadır.
- **Hata Teşhisi ve Tasarım İyileştirme:** İlgili IBD diyagramları mühendisler ve araştırmacılara sistemin iç yapısının genel bir bakışını sunduğu için, ilgili kişilerin potansiyel arıza noktalarını belirlemesini ve bu konularda araştırma yapılmasının kolaylaştırılmasını sağlamaktadır. Ayrıca tasarım eksiklikleri de sadece diyagramlar yorumlanarak saptanabilir ve sistem içerisinde eksik olan noktalar daha kolay bir şekilde belirlenebilir.
- **Egtegrasyon Planlaması:** Açık kaynak kodlu bir şekilde yayınlanacak çalışma sonrasında, çeşitli kurumlardaki öğrenciler veya araştırmacılar bir İHA oluşturulma aşamasında sistem mühendisliği kavramlarına dayandırılarak yapılmış bu tip diyagramları kullanarak çeşitli alt sistemlerin ve bileşenlerin bir araya getirilmesinde model tabanlı diyagramların avantajlarından faydalanabilir.

2.2.5. Kullanım Senaryosu diyagramları

UCD diyagramları, çeşitli gerçek kullanıcılar veya sistemler ve başka bir sistem arasındaki etkileşimleri tanımlamak ve göstermek için kullanılan, ilgili sistemlerin sunduğu çeşitli işlevleri ve yetenekleri gösteren, UML dili içerisinde değerlendirilebilecek bir görselleştirme aracıdır. Sistem analizi ve tasarımında sistemin davranışı ve amaçlanan işlevleri net bir şekilde ortaya koyan önemli bir araç olarak da ifade edilebilir. Bu diyagramlar, sistem işlevlerini ve kullanıcı etkileşimlerini yakalamak, analiz etmek ve ortaya koymak için yazılım geliştirmede, sistem mühendisliğinde ve iş analizinde yaygın olarak kullanılmaktadır. Tez çalışması içerisinde benimsenmiş SysML ve MBSE kavramları içerisindeki kullanımı ile sistemi referans olarak alarak uygulama geliştirmek isteyen kişilere geliştirme yaşam döngüsü boyunca bir kolaylık sunması amaçlanmıştır.

UCD diyagramlarında temel olarak kullanılan objeler Aktörler(Actors), Kullanım Senaryoları (Use Cases) ve İlişkiler (Relationships) olarak özetlenebilir. Bu objelerin tanımını aşağıda verilmiştir:

- **Aktörler:** Aktör objeleri temel olarak, belirli hedeflere ulaşmak için sistemle etkileşime giren, sistemin dışındaki varlıkları temsil etmektedir. Bu varlıklar

çeşitli gerçek kullanıcılar veya herhangi bir diğer sistem olabilir. Diyagramlar içerisinde aktörler genellikle adam figürü olarak temsil edilmektedirler.


- **Kullanım Senaryoları:** Kullanım senaryosu objeleri, sistemin sistem içerisindeki aktörlere sunduğu belirli işlevleri veya davranışları temsil etmektedirler. Böylelikle, sistemin aktörlere sağladığı eylemleri veya hizmetleri belirterek bir zarf oluştururlar. Diyagramlar içerisinde kullanım senaryosu objeleri oval bir şekil ile temsil edilmektedir.
- **İlişkiler:** İlişki objeleri, aktörler ve kullanım senaryoları arasındaki ilişkileri ve aktörlerin sistemin işlevleriyle nasıl etkileşime girdiğini gösteren bağlantılardır. Diyagram içerisinde düz veya kesikli çizgi ve oklar şeklinde gösterilmektedirler. Aktör ve kullanım senaryolarının arasındaki etkileşime bağlı olarak bu ilişkiler temelde Association, Include ve Extend tiplerinde olabilirler:
 - **Association:** Bir aktörü bir kullanım senaryosuna bağlayan ve aktörün söz konusu spesifik kullanım senaryosuyla etkileşime girdiğini gösteren bir çizgidir.
 - **Include:** Bu tip bir relationship ilişkisi, bir kullanım senaryosunun başka bir kullanım senaryosunun işlevlerini içerdiğini belirtir. Buna örnek olarak genel sistem mimarisine ait UCD diyagramında bulunan “İHA Operasyonu” kullanım senaryosu ve bu kullanım senaryosuna bağlı olan “Uçuş Kontrolü” verilebilir (Şekil 2.89). Çünkü, hava aracının uçuş esnasında kontrol edilmesi hava aracının uçurulması ve kullanılmasına bağlıdır.
 - **Extend:** Extend tipi relationship, isteğe bağlı veya alternatif işlevler ekleyerek başka bir kullanım senaryosunun genişletebileceğini gösterir. Bu tip bir senaryoda genellikle bir kullanım senaryosunun gerçekleştirilebilmesi için diğer kullanım senaryosu şartının gerçekleştirilmesi gerekir. Buna örnek olarak ise, yine Şekil 2.89’daki “İHA Operasyonu” kullanım senaryosu ve buna Extend tipi bir ilişki ile bağlı olan “İHA’nın Çalıştırılması” verilebilir. Burada, hava aracının uçurulması ancak öncelikle bu hava aracının çalıştırılması ile mümkün olmaktadır.

Geliştirilmiş olan referans hava aracı mimarisi içerisinde de UCD diyagramlarından faydalanılmak istenmiş ve IBD diyagramlarının bitirilmesinden sonra geliştirilmeye

başlanmıştır. Tez çalışması içerisinde UCD diyagramlarının oluşturulması da tamamlanarak referans mimari bitirilmiştir. UCD diyagramlarının geliştirilmesine ilişkin bilgiler aşağıdaki gibidir:

2.2.5.1.Genel sistem mimarisi UCD


Genel sistem mimarisi için oluşturulmuş olan UCD diyagramı (Şekil 2.89), sistemin kapsamını kısa ve öz bir şekilde tasvir ederek çeşitli varlıkların hava aracı ile nasıl etkileşime girdiğini göstermekte ve sistemin sınırlarını ve dış ortamla bağlantılarını temsili olarak ortaya koymaktadır. Diyagramın basitliği, sistem sınırlarını anlamada ve sistemler arasında etkili iletişimi ortaya koymada kolaylık sağlamaktadır. Ayrıca sistemin bağlamını ve dış unsurlarla ilişkilerini tanımlamaya yardımcı olmaktadır. Genel sistem mimarisi en üst seviyedeki diyagramları içerdiği için, UCD diyagramı da sisteme ve sistemin kullanımına genel bir bakış açısı sunmaktadır. Hava aracının bir operatör tarafından kullanılacağı ve bir teknisyen tarafından bakımlarının gerçekleştirilebileceği ortaya konmuş ve kullanım ile tamir-modifikasyon içerisinde IHA kabiliyetleri ortaya konmuştur.



Şekil 2.89. Genel sistem mimarisi UCD diyagramı

2.2.5.2.İtki sistemi UCD

Bir sonraki adımda itki sistemine ait UCD diyagramı oluşturulmuştur (Şekil 2.90). Bu diyagram içerisinde itki sistemi altındaki pervane ve motor gibi bileşenlerin birbirleri ile ve uçuş kontrol sistemi ile olan ilişkisi oluşturulmuştur.



Şekil 2.90. İtki sistemi UCD diyagramı


```

graph TD
    UCS[Uçuş Kontrol Sistemi]
    AS[Arm Switch]
    B[Buzzer]
    ASP([Arm Switch Pozisyonu])
    SP([Switch Pozisyonunu Al])
    UAD([Uzaktan Aktivasyon/Deaktivasyon])
    ASU([Alarm Ses Üret])
    BAS([Buzzer Alarm Seviyesini Al])
    BA([Buzzer Alarm Seviyesi])
    KSH([Kritik Sistem Hatası])
    DBU([Düşük Batarya Uyarısı])


    UCS --- ASP
    UCS --- BAS
    AS --- SP
    AS --- UAD
    B --- BAS
    B --- ASU
    ASP -.->|«extend»| SP
    BAS -.->|«extend»| BA
    UAD -.->|«include»| KSH
    UAD -.->|«include»| DBU
  
```

diyagramı oluşturulmuştur (EK-8a, EK-8b). Oluşturulmuş olan UCD diyagramı içerisinde uçuş kontrolcüsü ve FCC'nin yetenekleri, diğer sistemler ve aviyonik bileşenler ile haberleşmesi gösterilmiştir. Bu yeteneklerden bir tanesi, tez çalışması içerisinde de yapılmış olan diagnostik yaklaşımdır.

Uçuş kontrol sistemine ait UCD diyagramı içerisinde bu yaklaşıma da yer verilmiş ve FCC'nin kullanım senaryolarından bir tanesi “Diyagnostik” olarak oluşturulmuştur. Referans mimarinin bu kullanım senaryosu altında “Diyagnostik” kısmı kapsamlı bir şekilde ifade edilmiş ve ileride mimariyi kullanacak araştırmacılar için motor sağlığı, SoC, titreşim, akustik, video işleme gibi farklı diagnostik yaklaşımlara yer verilmiştir.

2.2.5.6.Güç sistemi UCD


Sonrasında, güç sistemi için bir UCD diyagramı oluşturulmuştur (Şekil 2.93). Bu sayede, güç sistemi ile ilgili işlevler ve etkileşimler görsel olarak özetlenerek, referans mimari olarak geliştirilen hava aracının güç sistemi kullanımı UCD diyagramı olarak ortaya konmuştur. Bu diyagram ile kullanım durumları temsil edilmiş ve ilgili sistem içerisindeki unsurların (Güç modülü ve batarya) birbiri ile ve dış sistemlerin (İtki sistemi, aviyonikler, kontrol sistemi vb.) güç sistemi ile nasıl etkileşime girdiğinin ayrıntıları gösterilmiştir.



Şekil 2.93. Güç sistemi UCD diyagramı

2.2.5.7.Sensörler UCD


Hava aracının operasyonel anlamda sorunsuz bir şekilde uçuşmasına yardımcı olan ve görev özelinde ihtiyaç duyulabilecek verileri iletmekle görevli sensörler kısmına ait UCD diyagramı “SensörlerUCD” başlığı ile oluşturulmuştur (Şekil 2.94). Böylelikle, uçuş kontrolcüsü tarafına iletilecek verilerin tüm sensörler tarafından (Manyetometre, IMU, GPS, hava hızı, barometre, ultrasonik) iletimi gösterilmiştir.



Şekil 2.94. Sensörler UCD diyagramı

2.2.5.8. Aviyonikler UCD

Son olarak ise, radyo kontrol alıcısı, mikrofon, telemetri ve kamera ekipmanları ile temsil edilmekte olan aviyonikler kısmı için bir UCD diyagramı oluşturulmuştur (Şekil 2.95). Bu diyagram içerisinde radyo kontrol alıcısı ve telemetrinin uçuş kontrolcüsü ile olan ilişkisi ortaya konarken, kamera ve mikrofon bileşenleri ise IBD diyagramlarında da olduğu gibi FCC ile ilişkilendirilmiştir. Bunun nedeni, daha önce de bahsedildiği üzere, bu tip ekipmanlardan gelen verilerin yüksek işlem gücü kapasitesi gerektirmesi ve ilgili kontrol bilgisayarlarının genellikle bu işlem yükünü başarıyla kaldırabilecek durumda olmalarındandır.



Şekil 2.95. Aviyonikler UCD diyagramı

Oluşturulan UCD diyagramlarının referans olarak sunulan hava aracı mimarisi bağlamında önemleri şu şekilde açıklanabilir:

- İşlevsellik: Kullanılan UCD diyagramları, aktörlerin belirli hedeflere veya işlevlere ulaşmak için sistemle nasıl etkileşimde bulunduğunu göstererek işlevsellik bağlamında sistem davranışlarını ve işlevlerini kullanıcının bakış

açısından özetlemektedir. Bu durum da sistem özelliklerinin tanımlanmasını ve önceliklendirilmesini kolaylaştırarak geliştiricilere yardımcı olmaktadır.

- Sınır Tanımlaması: UCD diyagramları, kullanıldıkları ilgili sistem veya alt sistemin sınırlarını tanımlamaya ve bu alt sistemlerin harici kullanıcılar veya sistemlerle (operatörler, teknisyenler, yer kontrol istasyonları vb.) etkileşimini netleştirmeye yardımcı olmaktadır.
- Analiz Kolaylığı: Geliştirilen UCD diyagramları, kullanıcı hedeflerine ve sistemin genel işlevlerine odaklanarak sistem ile ilgili gereksinimlerinin tanımlanmasına ve bu gereksinimlerin zaman içerisinde iyileştirilmesinin kolaylaştırılmasına yardımcı olurlar.
- Sistem Etkileşimleri: UCD diyagramları, sistem veya alt sistemlerin farklı kullanım durumlarının, işlevlerin veya sistemlerin birbirleriyle nasıl, ne şekilde etkileşime girdiğini ve ilişki kurduğunu göstererek hava aracına ait operasyonel iş akışının kapsamlı bir şekilde anlaşılmasına katkıda bulunurlar.

Sistem ve alt sistemlere genel bakış sağlayan BDD diyagramları, bu sistem ve alt sistemlerin detaylarını ortaya koyan IBD diyagramları, her alt sistem içerisinde bulunan ekipmanların özelliklerini ortaya koyan RD diyagramları ve sistemlerin fonksiyonelliğini ve diğer sistemlerle kullanım ilişkilerini ortaya koyan UCD diyagramların oluşturulması ile birlikte referans hava aracı mimarisi tamamlanmıştır.

Tez çalışmasının bir sonraki adımında, referans mimari içerisinde aviyonikler alt sisteminde ve sensörler alt sistemlerinde bulunan mikrofon bileşeninin ve IMU sensörünün kullanılması ile makine öğrenmesi destekli diyagnostik uygulama kısmına geçilmiştir. Bunun için uçuş kontrol sisteminin UCD diyagramında da belirtilmiş olan akustik veri ve titreşim verilerine bağlı bir uygulama geliştirilmesine karar verilmiş, ilgili çalışmalara aşağıdaki başlıklarda yer verilmiştir.


3. YAPAY ZEKA DESTEKLİ AKUSTİK DİAGNOSTİK

Tez çalışmasının bir sonraki adımında, uçuş kontrol sistemi UCD diyagramı içerisinde belirtilen diagnostik yaklaşımlardan akustiğe bağlı diagnostik yaklaşım benimsenmiştir. Bu diagnostik yaklaşım için AI yaklaşımı kullanılarak diagnostik uygulama yapılmasına karar verilmiştir. İHA’larda akustik ölçümlerin yoğunlaştığı kısımlardan bir tanesi pervane sesi ile yapılan çalışmalardır. Bu nedenle çalışmada, pervane hasarının AI kullanılarak diyagnostik çalışmasının yapılması uygun görülmüştür. Bu bağlamda, diagnostik, akustik, pervane ve bunların kombinasyonu ile ilgili çalışmalar hakkında öncelikle tez içerisinde ilgili başlıkta belirtilen literatür taramasına yer verilmiştir.

Literatür taramasından elde edilen bilgiler ışığında makine öğrenmesi, akustik, titreşim ve pervane konularının birleşimi ile yapılacak bir çalışmanın literatüre katkısının olacağı düşünülerek bu konu ile ilgili bir çalışmada karar kılınmıştır. Yapılan çalışma tüm detayları ile aşağıda belirtilmiştir.

3.1. Ekipmanlar ve Test Ortamı

Tez çalışmasının bu bölümünde, pervane gürültüsünün algılanması için rüzgara minimum miktarda maruz kalacak şekilde bir mikrofon pervanenin arka tarafına yerleştirilmiştir. Hasarsız pervane olarak 13x6.5 boyutunda plastik pervane kullanılmıştır. Literatür araştırmasında kullanılan pervanelerin genelinde pervane uçlarının kesilmesi ile aşırı hasar durumları altında çalışmalar yapıldığı görülmüş ve bu nedenle pervane ucu kesimi hariç özellikle daha minör sayılabilecek hasarlar olarak çentik şeklinde hasarlar altında da çalışma değerlendirilmiştir. Test esnasında kullanılmak üzere 2 pervane uçlarından farklı miktarlarda kesilmiş, 2 pervaneye çentik atılmış ve 1 pervanenin ise uç tarafı kısmi olarak inceltirilmiştir. Pervanelere verilen hasarlarda diğer bir önemli nokta, hasarların tamamının pervanenin her iki tarafına eşit miktarda verilerek simetrik bir hasar durumu oluşturulmasıdır. Her ne kadar pervane hasarları gerçek şartlar altında genellikle simetrik olarak oluşmasalar da, hasarların simetrik olarak verilmesi diyagnostik uygulama esnasında hasarın tespit edilmesini zorlaştırarak bu çalışmayı literatürdeki mevcut çalışmalardan farklılaştıracak unsurlardan biri olacağından ötürü tercih edilmiştir. Uygulama esnasında kullanılan tüm pervaneler ve hasar tipleri Şekil 3.1’den görülebilir.



Şekil 3.1. *Pervane hasarları*

Bir sonraki adımda ilgili pervane boyutu ile uyumlu bir motor seçilmesi gerekmiştir. Bunun için geliştirilmiş mimarideki RD diyagramlarından destek alınarak 2-4S pıl desteğine sahip 1200KV değerinde fırçasız tipte motor tercih edilmiştir (Görsel 3.1). Yine RD diyagramları göz önünde bulundurularak 5000 miliamper-saat (mAh) değerinde 3S'lik bir Lityum Polimer (LiPo) batarya kullanılmıştır (Görsel 3.2).



Görsel 3.1. *Fırçasız motor*




Görsel 3.2. LiPo batarya

Gelen radyo kontrol sinyallerinin durumuna göre pilden çekilecek akımı ayarlayarak elektrik motora iletilmesini sağlayan ESC olarak 2S ve 3S piller ile uyumlu olan 40 amper değerinde bir ekipman tercih edilmiştir (Görsel 3.3).



Görsel 3.3. Elektronik hız kontrolcüsü

İHA'ların kumanda edilmesinde günümüzde çoğunlukla 2.4 GigaHertz (GHz) frekansında çalışan kumandalar kullanılmaktadır. Çalışma içerisinde de bu frekansı destekleyen, 9 kanal çıkışına sahip ve doğru akım (DC) ile 4.8-10V aralığında çalışabilen bir radyo kontrol (RC) alıcısında karar kılınmıştır (Görsel 3.4).



Görsel 3.4. Radyo kontrol alıcısı

Hava aracını iti sisteminin kumanda etmek için ise 2.4 GHz frekansa sahip, 12 kanal destekli ve 4 Km mesafeye kadar maksimum menzili bulunan bir RC kumanda belirlenmiştir (Görsel 3.5). Bu kumanda üzerinde bulunan ekran vasıtası ile itki miktarının belirlenerek izlenebiliyor olması ilgili kumandanın seçiminde özellikle dikkate alınmıştır.




Görsel 3.5. RC Kumanda

Pervane gürültüsünün algılanmasında ise Evrensel Seri Veriyolu (USB) bağlantı noktasına sahip, tüm yönlerden ses alabilen (Omnidirectional) bir mikrofon belirlenmiştir (Görsel 3.6).



Görsel 3.6. *USB Mikrofon*

Tüm ekipmanlar belirlendikten sonra bir test düzeneği kurulmuş ve sistem akustik diagnostik uygulama için hazır hale gelmiştir (Görsel 3.7).




Görsel 3.7. *Test düzeneği*

Hasarsız ve hasarlı pervanelerin ses kayıtları alınırken parazit yaratabilecek dış sesler ile parazit veya dış sesi azaltıcı özel bir önlem alınmamıştır. Testlerin yapıldığı atölyenin camları test esnasında açık ve dışarıdan gelen seslere ve rüzgara karşı savunmasız bırakılmıştır. Ayrıca veri toplama ve diagnostik esnasında oda içerisinde çalışmakta olan batarya şarj aletleri, 3D yazıcı ve klima gibi gürültü yaratıcı aletler kapatılmamış, atölye kapısının açılma ve kapanma sesleri de engellenmeye çalışılmamıştır. Veri toplanmasından önce ortam gürültüsü ölçülmüş, ortamda hakim olan gürültü miktarının ortalama 39.9 desibel olduğu, atölye içerisinde bulunan ekipmanların

çıkarmış olduğu seslere bağılı olarak ise maksimum 73.7 desibele kadar çıktığı belirlenmiştir. Ayrıca, pervane testleri esnasında farklı hasar tiplerindeki pervanelere rastgele zamanlarda su püskürtülerek pervane sesini etkileyebilecek dış ortam koşulları yaratılmaya çalışılmıştır.

3.2. Yöntem

İlgili ekipmanların kurulmasından sonra mikrofona tarafından alınan ses kayıtlarının RaspberryPi veya herhangi bir benzer işlem gücüne sahip ekipman tarafından işlenebilmesi için ham(Raw) ses kayıtlarının (Şekil 3.2) Özellik Çıkarmı (Feature Extraction) teknikleri ile sayısal verilere dönüştürülmesi gerekmektedir.



Şekil 3.2. İşlenmemiş ses kaydı örneği

Bu dönüştürülen veriler, makine öğrenimi ve sinyal işleme esnasında kullanılmaktadır. Günümüzde özellikle AI uygulamalarının her alana uygulanabilir duruma gelmesi ve kullanımının artıyor olması AI'ın çalışacağı sistemlerdeki veriler ile baş etmenin önemli hale gelmesine yol açmakta ve sistem karmaşıklığının azaltılarak sistemlerin daha hızlı ve etkili çalışabilmesi için boyut azaltma tekniklerine ihtiyaç duyulmasına neden olmaktadır [90]. Boyut azaltma sayesinde hem sınırlı kaynaklara sahip sistemlerde depolama alanının yönetilmesi kolaylaşır hem de veri kümeleri içerisindeki gereksiz kısımların soyutlanması işlem süresini kısaltmaktadır [91]. Bu boyut azaltma teknikleri ise karşımıza Özellik Çıkarmı ve Özellik Seçimi (Feature Selection) olarak çıkmaktadır.

Özellik çıkarmına bakıldığında, kısaca işlenmemiş verilerin anahtar noktalarından daha fazla veri çıkarılabilmesi için kullanılmaktadır [92]. Kullanılma amacına

bakıldığında, özellik çıkarımı'nın verinin karmaşıklığını azaltırken mümkün olduğu kadar ilgili bilgiyi korumayı da amaçladığı, böylece makine öğrenimi algoritmalarının tahminlerde bulunmasını daha kolay ve verimli hale getirdiği söylenebilir [93, 94]. Makine öğrenmesinde en çok kullanılan özellik çıkarım tekniklerine bakıldığında ise, Timbre Features, Harmonic to Noise Ratio (HNR), Mel Frequency Cepstral Coefficients(MFCC), Wavelet Transform, Spectral Features, Time-Domain Features, Statistical Features, Temporal Features ve Deep Learning Based Features'dır. Bu teknikler içerisinde MFCC tekniği tercih edilmiştir.

3.2.1. Mel-Frequency Cepstral Coefficients (MFCC)

MFCC, özellikle konuşmacı tanıma, ses tanıma ve cinsiyet tanımlama gibi ses sinyali işlemede çeşitli uygulamalarda yaygın olarak kullanılan özelliklerden biridir [95]. MFCC tekniğinde, ses sinyalini genellikle yüksek frekanslara yükseltmek için bir ön filtre işlemi uygulanır. Bu, sinyal-gürültü oranını (Signal to Noise Ratio) iyileştirebilir ve ilgili özelliklerin tespit edilmesini kolaylaştırabilir. Sonrasında, sinyal uygulamaya bağlı olarak genellikle 20-40 milisaniye (ms) uzunluklarında parçalara bölünür ve sinyal frekansının kısa zaman aralıklarında analizine olanak tanır. Bu noktadan sonra her parça, spektral hataları veya sinyallerdeki ani geçişlerden kaynaklı kusurları en aza indirmek için pencere fonksiyonu denilen bir katsayı ile (Örneğin Hamming) çarpılır. Sonrasında, ilgili sinyali zaman alanından frekans alanına dönüştürmek için her bir parçaya Fourier Dönüşümü uygulanır ve bunun sonucunda sinyalin farklı frekanslarındaki enerji dağılımı olan güç spektrumu ortaya çıkar.

MFCC, aşağıdaki özellikleri sebebi ile çalışmadaki AI uygulamasında akustik özellik çıkarımı tekniği olarak tercih edilmiştir:

- Ses Hassasiyeti: MFCC tekniği, arka plan gürültüsüne ve ses sinyalindeki diğer değişikliklere karşı dayanıklıdır. Bu dayanıklılık, kaydedilen seslerin parazite veya değişken çevre koşullarının olduğu durumlarda önemlidir.
- Etkili Özellik Gösterimi: MFCC, ses sinyalinin hem spektral hem de zamansal özelliklerini yakalarlar. Bu bakımdan, sesin zaman içerisindeki spektral şeklini temsil ederek sınıflandırma veya diagnostik uygulamalar için önemli özellikleri yakalamada etkilidir.
- Yaygın Kullanım: MFCC, ses tanıma ve akustik işlemlerde literatür içerisinde de yaygın olarak kullanılmaktadır. Bu bakımdan literatürde yararlanılacak kaynak

bulmak oldukça kolaydır. Bu kaynaklardan bazıları doğrudan diagnostik uygulamalar için yapılmış ve yöntemlerinde başarı etmişlerdir. [96, 97] Bazıları ise İHA'nın yaymış olduğu akustik veri ile hava aracı varlığı üzerine çalışmışlardır [98-101]

Bu özellikleri bakımından, sesteki belirli kalıpları veya anormallikleri tanımlamanın çok önemli olduğu pervane akustik diyagnostiği gibi çalışmalar bağlamında, MFCC'ler makine öğrenimi algoritmaları için etkili bir özellik çıkarımı tekniği olarak hizmet etmektedir. Ses özellikleriyle ilgili hassas bilgileri yakalayarak AI modellerinin normal ve hasarlı pervane davranışıyla ilişkili farklı sesleri ayırt etmesini kolaylaştırmaktadırlar.

MFCC hesaplanmasında FFT kullanılmaktadır. Özellik çıkarımı esnasında ses sinyalinin FFT aşamasına hazırlanması bazı adımlar kullanılmaktadır. Bu adımlardan ilki, MFCC hesaplanırken, öncelikle sinyallerin birbirlerinden ayrıştırılmasıdır. Akustik sinyallerine bakıldığında zamana bağlı olarak değiştiği görülmekte ve bu işlem zamana bağlı olarak değişen durumları belirlemekte oldukça faydalıdır. Çalışma içerisinde “overlap frame” olarak da adlandırılan bu durum, özellikle ses sinyalinin küçük parçalara ayrılması ve incelenmesi için kolaylık sağlamaktadır. Bu çerçeveleri yaratırken her iki çerçeve arasındaki mesafeyi belirleyen bir parametre kullanılmıştır. Bu parametre “hop uzunluğu” olarak bilinmektedir. Yapılan çalışmada overlap çerçeve miktarı 2024, hop uzunluğu ise 512 olarak belirlenmiştir.

Bir sonraki adımda FFT metodunun etkili bir şekilde ses sinyaline uygulanabilmesi için bir pencere fonksiyonu yaratılmaktadır. Bunun için, literatürde de oldukça fazla kullanılan Hann pencere fonksiyonu kullanılmıştır (Denklem 3.1).

$$w[n] = 0.5(1 - \cos(\frac{2\pi}{N-1})) \quad (3.1)$$

Burada, n çerçeve içerisindeki index'i belirtmekte ve N elemanlı bir index için 0 ile N-1 arasında olmaktadır. N, bir çerçeve içerisinde toplam örnek sayısı, w[n] ise Hann penceresidir.

Hann penceresinin akustik sinyale uygulanmasından sonra bir pencere fonksiyonu elde edilir. Bu pencere fonksiyonunun elde edilmesi Denklem 3.2'de olduğu gibi ifade edilir.

$$y_w[n] = y[n] * w[n] \quad (3.2)$$

Denklem içerisindeki w[n] Hann penceresini, y[n] zamana bağlı ses sinyalini, $y_w[n]$ ise elde edilen pencere fonksiyonunu ifade eder.

Pencere fonksiyonu elde edildikten sonra, burada bulunan her pencerenin artık zamana bağılılıklarından soyutlanarak frekansa bağılı hale getirilmesi gerekmektedir. Bunun için ise FFT yöntemi pencere fonksiyonlarına uygulanır (Denklem 3.3)

$$Y[i] = \sum_{n=0}^{N-1} y_w[n] * e^{-j\frac{2\pi}{N}in} \quad (3.3)$$

FFT denkleminde, $Y[i]$ ilgili pencere fonksiyonunun FFT edilmiş halini, N değeri pencere sayısını, i değeri 0 ve $N-1$ arasındaki index'i, $y_w[n]$ pencere fonksiyonunu belirtmektedir.

FFT hesaplandıktan sonra bir frekans spektrumu elde edilmiştir. MFCC'yi bulmak için, elde edilen bu frekans spektrumunun bir sonraki adımda MEL ölçeği ile eşleştirilmesi gerekmektedir. Bu sayede gerçek frekans bilgisine karşılık gelen MEL değerleri hesaplanarak MFCC'nin bulunmasına katkı sağlamakta ve triangular fitrenin belirlenmesine yaramaktadır (Denklem 3.4)

$$m = 2595 \cdot \log_{10}\left(1 + \frac{f}{700}\right) \quad (3.4)$$

Denklemde bulunan f lineer frekansı, m ise MEL ölçeğini ifade etmektedir.

Bir sonraki adımda, bulunan MEL ölçeği değerleri ters formül uygulanarak tekrar merkezi frekanslara dönüştürülmüştür (Denklem 3.5).

$$f = 700 * \left(10^{\frac{m}{n}} - 1\right) \quad (3.5)$$

Burada ulunan f lineer frekansı, m MEL ölçeğini, n ise kaçınıcı elemanın dönüştürüldüğünü belirtmektedir.

Sonraki adımda, her pencere fonksiyonunun FFT çıkışlarından elde edilen değerlere bir filtre uygulanarak Mel Filter Bank elde edilmiştir (Denklem 3.6).

$$M[j] = \sum_{k=0}^{N-1} |Y[i]|^2 * H_j(i) \quad (3.6)$$

Denklemdeki $Y[i]$ her pencere fonksiyonunun FFT çıkışını, $M[j]$ Mel Filter Bank çıkışını, $H_j[i]$ j index değerine sahip değerin triangular filtre değerini, N ise FFT sayısını belirtmektedir.

Mel filter bank değerleri elde edildikten sonra ilgili her index için Mel güç spektrumu değeri bulunmuştur (Denklem 3.7).

$$\log M[j] = (\log M[j]) \quad (3.7)$$

Yukarıdaki denklemde $M[j]$ index j için bulunmuş olan enerjidir.

Tüm bu adımlardan sonra akustik sinyalin dağılımları elde edilmiştir. Bu dağılımlara ise Ayırık Kosinüs Dönüşümü (DCT) uygulanarak MFCC ile ilgili önemli katsayıların bulunması sağlanmıştır (Denklem 3.8).

$$c_i = \sum_{j=0}^{J-1} \log M[j] * \cos\left(\frac{\pi i(2j+1)}{2J}\right) \quad (3.8)$$

Yukarıdaki denklemde C_i , i indexinde bulunan katsayı, J , Melt filtre sayısıdır.

Bu işlemler bütün akustik sinyallere uygulandığında MFCC elde edilmiş olur. MFCC değerleri ilgili akustik veri hakkında karakteristik farklılıkları ortaya koyarak etkili bir makine öğrenmesi uygulaması yapılabilmesi için Random Forest algoritmasına girdi olarak kullanılmıştır.

3.2.2. Random Forest

MFCC tarafından elde edilen verilerin, daha sonrasında bir algoritma tarafından model eğitiminde veya kusurları tespit etmede kullanılması gerekmektedir. Yapılan çalışmanın sonucunda algoritmanın çıktısı iki farklı duruma sahip olabilmektedir. Bunlar; “Hasarlı” veya “Hasarsızdır”dır. Bu nedenden dolayı, AI ile geliştirilecek pervane hasarı diyagnostik uygulamasında çözülmesi gereken problem bir sınıflandırma problemidir. Bu tip bir sınıflandırma probleminde kullanılabilecek çeşitli algoritmalar mevcuttur. Bu algoritmalarından en yaygın olarak kullanılanları SVM, KNN, Random Forest, Gradient Boosting, NG Boosting, Yapay Sinir Ağları, DT, Naive Bayes, Fuzzy Logic ve LSTM veya Oto regresif Entegre Hareketli Ortalama (ARIMA) olarak söylenebilir.

Bu algoritmalar içerisindeki Gradient Boosting, NG Boosting veya SVM gibi bazıları verileri işleme şekillerine bağlı olarak diğerlerinden daha yavaş çalışabilmektedir. Bu nedenle tercih edilmemişlerdir. Yapay sinir ağları kullanarak diyagnostik uygulama yapmak her ne kadar literatürde kabul görmüş ve etkili bir yöntem olsa da, AI modelinin eğitilmesi için çok fazla veri gerektirdiği için yine tercih edilmemiştir. Bu noktada, kullanım kolaylığı, paralel işleme izin vermesi, ses dosyaları ile çalışmaya uygun olması ve seçilen özellik çıkarım tekniği olan MFCC ile uyum içerisinde çalışabilmesinden ötürü Random Forest algoritması AI modelini eğitmek için kullanılmıştır.

Random Forest algoritması, DT’den türemiş bir algoritmadır. Makine öğrenmesi konusu içerisinde karar ağacı yapıları oldukça sık kullanılan bir yapıdır. Ancak karar ağaçlarının karmaşık makine öğrenmesi senaryolarında çok fazla dallanıyor olması bu yapının model eğitim verilerinin (Trainin Set) hassaslığının fazla olmasına (Overfitting) ve sonuç olarak düşük bias ve çok yüksek varyans koşullarının ortaya çıkmasına neden olmaktadır. Random Forest ise işte bu karmaşıklığın üstesinden gelmek amacıyla, aynı

eğitim verisinin farklı kısımlarında birbirinden farklı çoklu karar ağacı eğitimini benimsemiş bir yaklaşımdır. Bu şekilde, her ne kadar verilerin yorumlanmasında bazı kayıplar ve Bias'da artış gözüküyor olsa da sonuçta ortaya çıkan modelin performansında çok fazla artış olmaktadır.

Random Forest ile makine öğrenmesi ve testleri yapılırken göz önüne alınması gereken en önemli parametre tahmincilerin sayısı (Number of Estimators) olarak belirtilebilir. Tahmincilerin sayısı modelin eğitimi esnasında kullanılacak bireysel ağaç sayısını belirtir. Her ağaç, bahse konu olan eğitim verilerinin rastgele bir alt kümesinde (Bagging) birbirinden bağımsız olarak eğitilir ve bu tüm bireysel ağaçlardan gelen tahminlerin oylanması ile son karar verilir. Bu nedenle tahmincilerin sayısının eğitilecek olan verinin miktarı ve tipine göre düzgün bir şekilde belirlenmesi gerekir.

Az sayıda ağaç kullanmak daha az karmaşık bir model oluşturulmasını sağlayarak potansiyel olarak hesaplamada göz önüne alınacak durumları azaltabilir ve eğitimi hızlandırabilir. Ama bununla birlikte, çok az sayıda ağaç kullanılması, modelin verilerdeki örüntüleri yakalanmasını zorlaştıracak ve eğitim ve test verileri arasında uyumsuzluğa neden olacaktır. Diğer yandan, fazla sayıda ağaca sahip olmak, varyansı ve aşırı uyumu azaltarak modelin doğruluğunu artırabilir. Ancak bu durumda hesaplama süresi ve bellek gereksinimleri artacaktır. Özellikle sınırlı kaynaklarla on-board olarak kullanılabilmesi hedeflenen bir yazılımda işlem gücü ve bellek kısıtlı olacağından ötürü Random Forest içerisindeki parametrelerin iyi düşünülerek seçilmesi gerekmektedir. Buradaki ideal tahminci sayısı genellikle veri kümesine, eldeki soruna ve sistem kaynakları ile model performansı arasındaki dengeye bağlıdır. Geliştirilmiş olan AI destekli diagnostik uygulamasında kullanılan donanımda 20 ile 250 tahminci sayıları arasında ara değerler seçilerek bir değerlendirme yapılmış ve nihai olarak 100 tahminci kullanımının kaynak-performans olarak en iyi sonucu verdiği görülmüştür.

3.2.3. Veri toplama

Daha öncesinde bahsedildiği üzere, geliştirilmiş AI destekli diagnostik uygulamada beş farklı hasar tipine sahip pervane ve 1 tane hasarsız pervane kullanılmıştır. Verilerin elde edilmesi amacı ile öncelikle ilgili altı pervanenin ses kayıtlarının oluşturulması gerekmiştir. Bunun için üç farklı itki (Thrust) miktarı belirlenmiştir. Bu itki miktarları sırasıyla %25, %50 ve %75'dir.

İtke miktarlarının belirlenmesinde %25'in altı ve %75'in üzeri özellikle dahil edilmemiştir. Bunun nedeni rolanti uçuş esnasında genel olarak itke miktarının %25'in altına düşmüyor olması ve %100'e yakın itke miktarlarının uçuş içerisinde çok nadir kullanılıyor olmasıdır. Ayrıca %75 itkinin üzerine çıkıldığında pervane hasarlarında oluşan sesin hasarsız pervane sesinden çok kolay bir şekilde ayırt edilebiliyor olması da dahil edilmemesinin sebeplerinden biridir. Hasarlı ve hasarsız pervaneler ile 10'ar saniyelik olmak toplamda 6000 saniyelik (1 saat 40 dk) ses kaydı alınmıştır (Şekil 3.3).


Ses Kayıtları		Hasarlı		Hasarsız		
	%25 İtke	%50 İtke	%75 İtke	%25 İtke	%50 İtke	%75 İtke
Hasar Tipi - 1	20 * 10sn = 200 sn	20 * 10sn = 200 sn	20 * 10sn = 200 sn	100 * 10 sn = 1000 sn	100 * 10 sn = 1000 sn	100 * 10 sn = 1000 sn
Hasar Tipi - 2	20 * 10sn = 200 sn	20 * 10sn = 200 sn	20 * 10sn = 200 sn			
Hasar Tipi - 3	20 * 10sn = 200 sn	20 * 10sn = 200 sn	20 * 10sn = 200 sn			
Hasar Tipi - 4	20 * 10sn = 200 sn	20 * 10sn = 200 sn	20 * 10sn = 200 sn			
Hasar Tipi - 5	20 * 10sn = 200 sn	20 * 10sn = 200 sn	20 * 10sn = 200 sn			
Toplam	100	100	100	100	100	100
		Eğitim (80%)		Validasyon (20%)		

Şekil 3.3. Pervane tiplerine göre ses kayıtları

Ses kayıtlarının alınması bittiğinde, 300 adet hasarsız pervaneye ait ve 300 adet hasarlı pervanelere ait ses dosyası elde edilmiştir. Her bir itki seviyesi için her hasar tipinden eşit sayıda örneklem mevcuttur. Şekil 3.3 üzerinden dağılımlar anlaşılabilir. Bu ses dosyalarının eğitim ve validasyon olarak ayrılması yapılmıştır. Toplam ses kayıt sayısının %80'i AI modelinin eğitiminde kullanılmış, kalan %20'lik kısmı ise AI modelinin validasyonunda kullanılmıştır. AI modelinin eğitiminde ve ses dosyalarının işlenmesinde Python programlama dili tercih edilmiştir. Bu dilin seçilmesinin nedeni AI anlamında altyapı ve geliştirici desteğinin oldukça fazla olması ve on-board sistemlerde kullanımının kolay olmasıdır. Daha önce de bahsedildiği üzere, işlenmemiş ses dosyalarının öncelikle Random Forest ile yapılacak model eğitime uygun hale getirilmesi gerektiğinden önce MFCC'ye ait hasarlı ve hasarsız pervanelerin eğitim ve validasyon verilerinin elde edileceği kodlamalar yapılmıştır.

Hasarlı pervanelerin özellik çıkarımı için kodlama esnasında ses dosyaları ile işlemler yapılırken hem kullanım kolaylığı hem de MFCC desteği nedeniyle Python librosa kütüphanesi tercih edilmiştir. Bunun için öncelikle ses dosyalarının %80'i eğitim, %20'si test(validasyon) olarak ilgili klasörlere konulmuş ve kod içerisinde ilgili path verisi oluşturulmuştur. Sonrasında bu dosya içerisindeki itki seviyeleri ile ilgili path bilgileri ve hasar tipleri tek boyutlu bir dizi olarak oluşturulmuştur. Bir sonraki adımda 3 adet for döngüsü kullanılarak her bir itki seviyesinde her bir hasar tipi için dosyalar tek tek alınarak MFCC özellikleri çıkarılmış ve bu veriler Virgülle Ayrılmış Değerler (CSV) dosyası olarak kaydedilmiştir (EK-9).

MFCC özellik çıkartımı işlemi sonrasında 10 saniyelik ses dosyalarının 3 farklı itki seviyesi için görselleştirilmiş örneği Şekil 3.4'de mevcuttur. Buna göre, farklı itki seviyelerinde 10'ar saniyelik ses görsellerinin her biri birbirinden göz ile de görülür şekilde farklı olması MFCC işleminin tam olarak işlevini açıklamaktadır. Şekil 3.4 aslında, CSV dosyasındaki 10 saniyelik üç farklı verinin görselleştirilmiş halidir.



Şekil 3.4. Görselleştirilmiş MFCC özellik çıkarımı verileri

İlgili CSV dosyasının içerisinde bakıldığında, eğitim verileri için yaklaşık 103000, Validation verileri için yaklaşık 25000 satırdan ve 20 sütundan oluşan 2 boyutlu bir matris gibi olduğu görülebilir (Şekil 3.5).

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
-382.247	106.0942	31.94937	0.794892	16.42037	12.87442	9.285437	10.08944	10.3162	-3.10904	-7.80362	-4.21279	-0.34711	-0.5434	-3.23576	-9.575	-2.11112	-2.37221	-0.33797	-6.72636
-379.426	82.59557	26.9757	-3.02972	15.70216	19.15273	14.05115	9.557657	7.995031	-0.31458	-5.40125	-5.40234	-1.42527	-1.50842	-7.91359	-5.23202	-0.37355	-3.45046	-4.93168	-6.52548
-394.498	70.44908	14.09438	-7.79242	20.2561	27.26017	15.38913	12.05296	8.030939	0.087903	-4.71993	-5.43277	0.644004	-0.38109	-11.1279	-3.10643	-3.04968	-5.82406	-7.41109	-6.8376

Şekil 3.5. MFCC özellik çıkarımı verileri

Buradaki sütunlar 3 farklı özelliği belirtmektedir. 0. sütun “DC Bileşen” olarak adlandırılmaktadır ve ses sinyalinin enerji veya güç miktarını temsil etmektedir. 1 ve 12. sütunlar arasındaki kısım “Katsayılar” olarak adlandırılmaktadır. Bu kısımda bulunan katsayılar ses sinyalinin spektral zarfını temsilen oluşturulmaktadır ve sesin farklı frekans bantları ile ilişkilendirilerek spektrumun şeklinin bilgisini taşır. 13 ve 19. Sütunlar arasındaki kısım ise “Delta MFCC” olarak adlandırılmaktadır ve orijinal MFCC verisinin zaman içerisindeki değişimini belirterek ses sinyalinin dinamikleri veya geçici (değişen) karakteristikleri hakkında bilgi vermektedir. Bir sonraki adımda yukarıda bahsedilen MFCC özellik çıkarımları adımlarının aynısı hasarsız pervane ses dosyalarına uygulanmıştır (EK-10).

Hasarlı ve hasarsız pervane seslerinin MFCC yöntemi ile özellik çıkarımı yapıldıktan sonra “damaged_propellers_train_MFCC.csv”, “damaged_propellers_validation_MFCC.csv”, “undamaged_propellers_train_MFCC.csv” ve “undamaged_propellers_validation_MFCC.csv” adlı 4 CSV dosyası elde edilmiştir. Bu işlem tamamlandıktan sonra Random Forest algoritması kullanılarak bu veriler ile AI modeli eğitimi ve validasyonları yapılmıştır (EK-11).

AI model eğitimi için Python içerisinde “sklearn” olarak adlandırılan “scikit-learn” kütüphanesi kullanılmıştır. Bu kütüphane Python içerisinde oldukça sık kullanılan açık kaynak kodlu bir makine öğrenmesi kütüphanesidir ve NumPy, SciPy ve Matplotlib kütüphaneleri esas alınarak geliştirilmiştir. Özellikle sınıflandırma (Classification), regresyon, kümeleme (Clustering) gibi AI uygulamaları için çeşitli algoritmaları içeren geniş bir yelpazeye sahiptir. İlgili çalışmada kullanılması planlanan Random Forest algoritması da “sklearn” içerisinde mevcuttur. Kod içerisinde kütüphane tanımlaması yapıldıktan sonra, önce hasarlı ve hasarsız veriler yukarıda bahsedilen ilgili CSV dosyalarından program içerisindeki değişkenlere aktarılmış, hem hasarlı hem de hasarsız pervane verilerine ait eğitim ve validasyon verileri birbiri ile kombine edilmiştir. Sonrasında, daha önce de bahsedilen tahminci değeri girilerek bir model oluşturulmuş ve bu model eğitim verileri ile eğitilmiştir. Daha sonrasında ise validasyon verileri kullanılarak modelin hassasiyeti belirlenmiştir.

Tüm eğitim ve validasyon işlemleri bittikten sonra ilgili AI modeli yine Python içerisinde bulunan ve özellikle yüksek işlem gücü ile hafıza(memory) gerektiren veriler ile uğraşırken faydalı olan “joblib” kütüphanesi kullanılarak Python Pickle (PKL) dosyası olarak dışarı aktarılmıştır. Dışa aktarım sırasında PKL dosyası kullanılmasının sebebi, modelin her kullanımda tekrar eğitilmesine gerek kalmadan farklı ortam veya donanımlar üzerinde kolay bir şekilde yeniden kullanılabilmesi içindir.

Random Forest ile eğitilmiş ve dışarı aktarılmış AI modeli ile sonrasında denemeler yapılmış ve modelin iyi bir performans sergilediği görüşmüştür. Modelin çalıştırılabilmesi için EK-12 içerisinde belirtilen kodlama yapılmıştır. Bu kod içerisinde kullanılmakta olan ses dosyası herhangi bir eğitim veya validasyon veri setinin bir parçası olmadığı için işlenmesi ve sonucun ekranda gösterilmesi çok daha kısa sürmüştür (Yaklaşık 3-4 saniye). Programın çalışması bittikten sonra komut satırında “Propeller is damaged” veya “Propeller is not damaged” şeklinde ibare görülmektedir.

İlgili çalışma sonrasında elde edilen modeli değerlendirmek için 3 farklı araç kullanılarak modelin performansı ve başarısı değerlendirilmiştir. Bunlar; “Feature Importance”, “Receiver Operating Characteristic” ve “Confusion Matrix”dir.

3.2.4. Feature Importance (FI)

Feature Importance (FI), tahmine dayalı bir AI modelinde en alakalı veya etkili özellikleri (Örneğin MFCC özelliklerini) belirlemek için kullanılan bir tekniktir. FI değerlendirmesi ile birlikte kullanılan verideki hangi özelliklerin modelin tahminleri veya karar verme süreci üzerinde en fazla etkiye sahip olduğunun anlaşılmasına yardımcı olmaktadır.

3.2.5. Receiver Operating Characteristic (ROC)

Receiver Operating Characteristic (ROC), özellikle sınıflandırma içeren modellerin performansını değerlendirirken kullanılan, grafiksel olarak kullanıcıya fikir veren bir araçtır. Verilerin sınıflandırılması esnasında kullanılan eşikler sonucunda ortaya çıkan hassaslık olarak da adlandırılabilir Gerçek Pozitif(TP) ve Yanlış Pozitif(FP) durumlar arasındaki ilişkiyi gösterir ve dolayısıyla model başarısı hakkında bilgi verir.

3.2.5.1. Gerçek Pozitif Oranı (TPR)

Gerçek Pozitif Oranı (TPR), AI modeli tarafından doğru bir şekilde tahmin edilen pozitif değerlerdir ve aşağıdaki şekilde hesaplanmaktadır (Denklem 3.9).

$$TPR = \frac{True\ Positives}{True\ Positives + False\ Positives} \quad (3.9)$$

3.2.5.2. Yanlış Pozitif Oranı (FPR)

Yanlış Pozitif Oranı (FPR), AI modeli tarafından hatalı bir şekilde pozitif olarak tahmin edilen negatif değerlerdir ve aşağıdaki şekilde hesaplanmaktadır (Denklem 3.10).

$$FPR = \frac{False\ Positives}{True\ Positives + False\ Positives} \quad (3.10)$$

TPR ve FPR değerleri ROC çizgisi ve Eğrinin Altındaki Alan (AUC) değerleri elde edilerek TPR'ye karşılık gelen FPR değerlerine bağlı olarak ROC grafiği çizilmektedir. ROC çizgisinin altında kalan alan AUC olmakta ve 0 ve 1 değerleri arasında değişmektedir. Alanın 1 olması %100 başarı oranı göstermekte, %50'nin altında olması ise modelin sınıflandırma işleminde başarılı bir iş ortaya koyamadığını ve sınıflandırma tahminlerinin rastgele tahminlerden öteye geçemediği belirtmektedir.

3.2.6. Karmaşıklık Matrisi

Karmaşıklık Matrisi (Confusion Matrix), sınıflandırma için kullanılan bir AI modelinin başarısını değerlendirmede kullanılan diğer bir yöntemdir. ROC'den farklı olarak tablo şeklindedir ve model içerisindeki veri setinin sadece TP ve FP taraflarına değil, aynı zamanda Doğru Negatif (TN) ve Yanlış Negatif (FN) taraflarına da odaklanır. TN ve FN formülleri yukarıdaki formüller ile neredeyse aynı olduğu için ayrıca burada belirtilmemiştir.

Karmaşıklık matrisi tabloları, AI uygulamalarında özellikle farklı sınıflardaki performanslar hakkında detaylı bilgi sağladığı ve sınıflandırma esnasında modelin güçlü ve zayıf yönlerini detaylı şekilde ortaya koyduğu için önemlidir. Bu nedenle, çalışma içerisinde kullanılan AI modeli için de bir karmaşıklık matrisi oluşturulmuştur.

İki durumlu sınıflandırma sonuçlarını oluştururken karmaşıklık matrisi tablolarının içerisinde dört kısım oluşmaktadır. Bunlardan bir tanesi hasarlı pervaneye ait validasyon verilerinin kaç tanesinin doğru bir şekilde hasarlı olarak tahmin edilebildiği (TP), bir diğeri ise kaç tanesinin yanlış bir şekilde hasarsız olarak tahmin edildiğidir (FN). Bir diğer

durumda ise hasarsız pervanelere bakılır. Hasarsız pervanelerin kaç tanesinin doğru bir şekilde hasarsız olarak tahmin edildiği (TN), veya kaç tanesinin yanlış bir şekilde hasarlı olarak tahmin edildiği (FP) model performansını belirlemede kullanılmaktadır.

Karmaşıklık matrisi ile bu değerler elde edildikten sonra TP, FP, TN ve FN değerleri Precision, Recall, Accuracy, F1 Score gibi performans metriklerinin hesaplanmasında kullanılmaktadırlar.

3.2.6.1.Precision

Precision veya hassaslık, TP değerlerinin tüm pozitif olarak nitelendirilen tahminlere olan oranı şeklinde ifade edilmektedir (Denklem 3.11).

$$Precision = \frac{TP}{TP+FP} \quad (3.11)$$

3.2.6.2.Recall

Recall aynı zamanda TPR değerini göstermektedir (Denklem 3.9). TP değerlerinin TP ve FN değerlere oranı ile bulunmaktadır.

3.2.6.3.Accuracy

Doğruluk olarak da nitelendirilebilecek olan Accuracy değeri, modelin doğrudan başarı yüzdesini vermekte ve bu nedenle tüm performans metrikleri içerisinde en önemli olanlarından biri olarak sayılmaktadır. Hasarlı ve hasarsız olarak doğru bir şekilde sınıflandırılmış değerlerin tüm değerlere oranı olarak ifade edilebilir (Denklem 3.12).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.12)$$

3.2.6.4.F-1 Score

Diğer bir performans metriği olan F-1 skoru, hassaslık ile recall arasında bulunan dengeyi belirtmektedir. Bunun belirlenmesi için ise her ikisinin ortalaması alınmaktadır (Denklem 3.13).

$$F1\ Score = 2 * \frac{Precision*Recall}{Precision+Recall} \quad (3.13)$$

4. YAPAY SİNİR AĞI İLE TİTREŞİME BAĞLI DİAGNOSTİK

Tez çalışmamasının sonraki adımında, İHA modellemesi içerisinde belirtilen diagnostik yaklaşımlardan titreşime bağlı diagnostik yaklaşım benimsenmiştir. Böylelikle akustik olarak yapılmış olan çalışmayı desteklemek ve hasarlı ve hasarsız pervaneleri sınıflandırmada farklı bir yaklaşım benimsenmesi hedeflenmiştir. Bu farklı yaklaşımın ilk adımı olarak titreşime bağlı bir diyagnostik uygulama yapılmasına karar verilmiştir.


Yapılması planlanan ve yapay zeka destekli akıllı algılama olarak nitelendirilen çalışmanın önemli noktalarından bir tanesi, kullanılacak ekipmanın özellikle normal İHA operasyonları içerisinde kullanılabilecek bir sensör olmasıdır. Titreşim verisi ile akustik diyagnostik uygulamanın desteklenmesi esnasında bu koşul göz önüne alınmıştır. Bu durum ayrıca, kolaylıkla ulaşılabilen ve aynı zamanda bir İHA içerisinde ivmeölçer olarak da kullanılabilen ADXL345 sensörünün tercih nedenlerinden biridir. Böylece, bir hava aracı içerisinde normal şartlar altında farklı işlevler için kullanılabilecek bir ekipmandan gelen veriler kullanarak diyagnostik olarak çıkarımlar da yapılabileceğinin ortaya konulması hedeflenmiştir.

Bu diagnostik yaklaşım için ANN kullanılarak diagnostik uygulama yapılmasına karar verilmiştir. İHA’larda titreşim ölçümlerinin uygulanabileceği kısımlardan bir tanesi pervane ile yapılabilecek çalışmalar olduğu için çalışmada, pervane hasarının ANN kullanılarak titreşime bağlı diyagnostik çalışmasının yapılmasına karar kılınmıştır. Bu bağlamda, diagnostik, titreşim, pervane ve bunları konu alan ilgili çalışmalar hakkında öncelikle detaylı literatür taraması yapılmış, böylelikle hem hata teşhisinde kullanılan yöntemleri anlamak hem de genel olarak literatür içerisinde ne gibi eksiklikler bulunduğunu belirlemede kolaylık sağlamıştır. İlgili çalışmalara litüratür taraması başlığı altında belirtilmiştir.

4.1. Ekipmanlar ve Test Ortamı

Titreşime bağlı diyagnostik başlığı altında gerçekleştirilen çalışmada, bir önceki çalışmada kullanılmış ve tez içerisinde belirtilmiş olan pervaneler, motor, batarya, ESC, RC alıcısı ve RC kumandası herhangi bir değişiklik yapılmadan kullanılmıştır. Dolayısıyla çalışma içerisinde kullanılan hasarlı pervanelerin hasarları bir önceki ile aynı olup, elde edilen sonuçlar farklı bir yaklaşımla ilk çalışmayı desteklemektedir.

Titreşim seviyelerinin algılanması için ADXL345 IMU sensörü (Görsel 4.1) kullanılmıştır. Titreşim sensörü olarak ADXL345 seçilmesinin temel sebebi, verileri çoğu titreşim sensörünün aksine dijital değil analog olarak kullanıcıya sağlamasıdır. Sinyalin analog olarak sağlanması sonucunda ilgili ekipmanda sadece titreşim olup olmadığından ziyade titreşimlerin miktarları hakkında da bilgi alınabilmektedir. Bu durum her ne kadar dijital çıkış veren bir titreşim sensöründe iki sinyal arası zamanın ms cinsinden ölçülmesi ile sentetik olarak sağlanabilse de, analog sinyale sahip bir sensör kullanımının çalışma sonuçlarının doğruluğu açısından önemli olduğu düşünüldüğünde bu tip sensör kullanımının daha uygun olduğuna kanaat getirilmiştir.




Görsel 4.1. ADXL345 IMU sensörü

Tercih edilmiş olan ADXL345 titreşim sensörü, 3 eksenle titreşimleri algılamaya olanak sağlamakta, küçük boyutları sayesinde özellikle ağırlığın dikkate alınması gerektiği İHA gibi mobil uygulamalar ile kullanımı basit olan bir ekipmandır. Bazı teknik özellikleri Tablo 4.1’de gösterilmiştir.

Tablo 4.1. ADXL345 Teknik Özellikleri


Boyut	3mm x 5mm x 1mm
Ağırlık	30 mg
Çalışma Voltajı Aralığı	2.0 – 3.6V
Ölçüm Esnasında Akım Tüketimi	23 μ A
Bekleme Durumunda Akım Tüketimi	0.1 μ A
Çalışma Sıcaklığı Aralığı	-40 °C - +85 °C
Elde Edilen Örneklem Frekansı	50 Hz

İlgili titreşim sensörünün algıladığı verilerin toplanması ve model eğitiminde kullanılmak üzere bilgisayara iletilmesi için Arduino Uno kullanılmıştır (Görsel 4.2). Bu sayede sensör üzerinden alınan analog veriler Arduino'nun üzerinde bulunan analog giriş ile alınarak USB bağlantısı ile bilgisayar üzerinde çalışmakta olan Arduino Geliştirme Ortamı (IDE) tarafına gönderilmiştir.



Görsel 4.2. *Arduino Uno*

Tüm ekipmanların ve test bench kurulması için sensör bacakları lehimlenmiş, jumper kablo vasıtası ile Arduino'nun veri girişlerine bağlanmıştır (Görsel 4.3).




Görsel 4.3. *ADXL345-Arduino bağlantısı*

Bir sonraki adımda, Arduino bilgisayara bağlanmış, motor ile ESC ve RC alıcısının kurulumları gerçekleştirilmiştir. En son olarak ise sensörün kurulumu tamamlanmıştır. Sensörün geniş sıcaklık çalışma aralığı göz önünde bulundurularak motorun arka tarafına monte edilmiştir (Görsel 4.4).

Arduino'nun IDE üzerinde sensör verilerini alabilmesi için ilgili yazılım geliştirilmiş ve titreşime bağlı diagnostik uygulama için hazır hale gelmiştir (Görsel 4.5).



Görsel 4.4. *Titreşim sensörü konumu*



Görsel 4.5. *Titreşim sensörü test düzeneği*

4.2. Yöntem

Test düzeneğinin kurulması, titreşim sensörünün yerleştirilmesi ve Arduino ile bağlantısının yapılması ve düzgün bir şekilde çalıştığının doğrulanması sonucunda ADXL345 titreşim sensörü ile öncelikle veriler toplanmıştır.


Toplanmış olan verilerden en iyi şekilde faydalanabilmek adına özellik çıkarım tekniklerinden faydalanılmıştır. Özellik çıkarım teknikleri uygulanmış verilerin içerisinde bulunabilecek ve ANN'i etkilemesi muhtemel ekstrem veya aşırı olarak nitelendirilebilecek verilere karşın Z-Score Normalizasyonu tekniği kullanılarak veriler standardize edilmiştir.

Z-Score Normalizasyonu sonucunda elde edilen veriler İleri Yönlü Yapay Sinir Ağı (FFNN) kullanılarak eğitilmiştir. Eğitim sonrasında validasyon ve testleri yapılarak modelin iyi sonuç verdiği doğrulanmıştır.

4.2.1. Veri Toplama


İlgili ekipmanların kurulumunun bitmesinden sonra titreşim sensörü tarafından titreşim kayıtları alınmıştır (Şekil 4.1).

İkinci aşamada geliştirilen titreşime bağlı diyagnostik için akustik diyagnostik çalışmasında kullanılan pervaneler kullanılmıştır. Bu pervaneler daha öncesinde de olduğu gibi üç farklı itki altında çalıştırılmıştır. Bu itki miktarları sırasıyla %25, %50 ve %75'dir. Hasarlı ve hasarsız pervaneler yine daha önceki çalışmadakine benzer şekilde 10'ar saniyelik olmak toplamda 6000 saniyelik(1 saat 40 dk) titreşim kaydı alınmıştır.



Şekil 4.1. Üç eksenli titreşim örneği

Kullanılan titreşim sensörünün frekansı 50Hz olduğu için, saniye başına 50 adet, kayıt başına ise her biri üç eksenden birine ait 500 satır veri toplanmıştır. Tüm hasarlı ve hasarsız pervaneler ile veriler toplandıktan sonra ise Şekil 4.2’de görüldüğü üzere pervane-itki başına 51.000 satır veri elde edilmiştir.



Şekil 4.2. Pervane tiplerine göre titreşim kayıtları

Hasarlı pervane ve hasarsız pervanelerden toplanan ve FFNN tarafından eğitilecek toplam veri miktarı 918.000 satır olmuştur. Böylelikle, ANN’lerin etkili bir şekilde eğitilebilmesi için genellikle fazla miktarda veriye ihtiyaç duyması sebebi ile yaşanabilecek bir dezavantajın önüne geçilmeye çalışılmıştır.

Toplanmış titreşim verilerinin hiç işlenmeden doğrudan FFNN’ye iletilmesi sonucunda doğruluk oranlarının düşmemesi için akustik diyagnostik uygulamasında olduğu gibi özellik çıkarım tekniklerinin kullanılmasına karar verilmiştir. Özellik çıkarım tekniklerinde ise verideki önemli özelliklerin kaybolmadan işlenebilmesini ve boyut azaltımı sonrasında modelin eğitilmesi ve modelin kullanılması esnasında zamandan tasarruf sağladığı için istatistiksel özellik çıkarım tekniklerinin uygulanması uygun görülmüştür.

Hasarlı ve hasarsız pervanelerin birbirlerinden ayırt edimesinde kullanılacak bir AI uygulamasında titreşimden elde edilmiş olan verilerin dağılımlarının belirlenmesinde ve titreşim karakteristiklerinin ortaya konmasında başarılı sonuçlar vereceği ön görülen

Ortalama, Orta Değer, Standart Sapma, Skewness ve Kurtosis özelliklerinin birlikte kullanılmasına karar verilmiştir.

4.2.2. İstatistiksel özellik çıkarımı ve Z-Score normalizasyonu

Yapılan AI destekli titreşime bağlı diagnostik uygulamada, analog çıkışa sahip bir sensör olan ADXL345 ile toplanan verilerin AI model eğitiminde kullanılmasından önce önemli özelliklerinin ortaya çıkarılması için öncelikle Ortalama Değer, Orta Değer, Standart Sapma, Skewness ve Kurtosis istatistiksel özellik çıkarımı tekniklerinden faydalanılmıştır. Kullanılan istatistiksel özellik çıkarımı tekniği sonrasında veriler normalizasyon adımından da geçerek eğitime hazır hale getirilmiştir.

4.2.2.1. Ortalama Değer

Kullanılan istatistiksel özellik çıkarımlarından biri olan Ortalama Değer (μ), bir veri seti içerisinde bulunan değerlerin aritmetik ortalamasını vermektedir (Denklem 4.1).

$$Mean(\mu) = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.1)$$

Verilen denklemde n toplam veri miktarı, x_i ise anlık hesaba katılan veridir.

4.2.2.2. Orta Değer

Orta değer, bir veri seti içerisindeki sıralamada orta noktaya karşılık gelen değerdir. Sayısal veriler küçükten büyüğe doğru sıralandığında Orta değer, aslında veri setini ortadan ikiye bölen veridir de denebilir. Ortalama değer, veri setinin aritmetik ortalaması olduğu için, veriler içerisindeki ekstrem olarak adlandırılabilen aykırı verilerden fazlasıyla etkilenenektir. Orta değer ise veri seti uzayının geometrik orta noktası olduğundan dolayı veri seti içerisinde bulunan ekstrem verilerden daha az etkilenmektedir. Küçükten büyüğe doğru sıralanmış n adet değer içeren bir veri seti için, eğer “ n ” değeri tek sayı ise, Orta değer doğrudan orta noktaya (Denklem 4.2 ve Denklem 4.3), “ n ” değeri çift sayı ise ortada bulunan iki değer ortalamasına eşittir.

$$Orta\ Değer = \frac{x_{(n+1)}}{2} \quad (4.2)$$

$$Orta\ Değer = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2})+1}}{2} \quad (4.3)$$

4.2.2.3. Standart Sapma

Standart Sapma (σ), bir veri setinde bulunan değerlerin veri uzayı boyunca dağılmasının bir ölçüsüdür. Standart sapmanın yüksek veya düşük olması veriler hakkında bazı çıkarımlar yapmaya olanak sağlayabilir. Düşük değere sahip bir standart sapma, değer dağılımlarının veri setinin ortalama değerine benzer şekilde olduğunu gösterir. Yüksek miktarda olması durumunda ise, veri seti içerisinde bulunan verilerin geniş bir yelpaze aralığında bulunduğunu belirtir. Standart sapmanın hesaplanması için öncelikle ortalama değer ve varyans değerlerinin bulunması gerekmektedir. Varyans değeri Denklem 4.4’de görüleceği üzere veri seti üzerindeki herhangi bir noktadan ortalama değer çıkarılması ve bu işlem sonucunun karesinin alınması ve bu durumun tüm veri setine yapılarak eleman sayısına bölünmesi ile bulunmaktadır.

$$Varyans(\sigma^2) = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \quad (4.4)$$

Standart sapma ise, varyansın kareköküne eşittir (Denklem 4.5).

$$Standard\ Deviation(\sigma) = \sqrt{Variance} = \sqrt{\sigma^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2} \quad (4.5)$$

4.2.2.4. Skewness

Skewness, istatistik biliminde ve olasılık kuramında sıklıkla kullanılan bir değer olmakla birlikte, bir reel sayının veya değişkenin yapılmış olan bir olasılık dağılımında bu dağılımın ortalama değere göre ne kadar simetrik olmadığının bir göstergesidir. Hesaplanması sonrasında küme içerisindeki verilerin ne kadar sola doğru veya ne kadar sağa doğru bir çarpıklık içerisinde olduğu belirlenir. Eğer veri dağılımında ortama değere göre sol taraftaki veriler daha fazla ise bu duruma “Negatif Skewness”, sağ taraftaki veriler daha fazla ise bu duruma “Pozitif Skewness” denir. Skewness hesaplanmadan önce ortalama değer ve standart sapma değerleri hesaplanır. Bunlara bağlı olarak Skewness hesaplanabilir (Denklem 4.6).

$$Skewness = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^3 \quad (4.6)$$

4.2.2.5.Kurtosis

Kurtosis, veri dağılımının genişliği ve uç noktaları hakkında bilgi vermektedir. Böylece, verilerin uç değer üretip üretmemeye karşı olasılıklarının belirlenmesine yardımcı olur. Denklem 4.7’de Kurtosis’in genel formülü verilmiş olup, Kurtosis hesabından önce ortalama değer ve standart sapma hesaplamalarının yapılmış olması gereklidir.

$$Kurtosis = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \mu}{\sigma} \right)^4 \quad (4.7)$$

Z-Score Normalizasyonu, bir veri kümesinde bulunan verilerin ortalama değerlerinin 0, standart sapma değerlerinin ise 1 olacak şekilde normalleştirilmesinde kullanılmaktadır. Bu durum veri seti içerisinde bulunan tüm verilerin standartlaştırılmasını ve özelliklerinin karşılaştırılmasını kolaylaştırmaktadır. Böylelikle, eğitilecek olan yapay sinir ağına sağlanacak verilerin özelliklerinin standart hale getirilmesi, ekstrem verilerin sayısal olarak küçük veriler üzerinde baskınlık kurmasının engellenmesi ve model eğitiminin daha hızlı bir şekilde yapılarak model öğrenim performansının maksimuma çıkarılması hedeflenmiştir.

Titreşim verilerinden yukarıda elde edilen özellikler (Ortalama değer, Orta değer, Standart Sapma, Skewness, Kurtosis), bir sonraki adımda her bir veri seti (Sütun) için bir özellik vektörü olarak tutulmuştur. Ardından bu verilerde Z-Score Normlizasyonu (Z) kullanılarak verilerin ölçeklenmesi sağlanmıştır (Denklem 4.8).

$$Z = \frac{x_i - \mu}{\sigma} \quad (4.8)$$

Denklemden bahsedilen ortalama değer ve standart sapma ham durumdaki işlenmemiş titreşim verilerinin değerlerini değil, özellik çıkarımı sonrasında elde edilen ve her bir CSV dosyasının içerisinde bulunan her bir sütundan elde edilen Ortalama değer, Orta değer, Standart Sapma, Skewness, Kurtosis’den oluşturulmuş olan özellikler vektörünün ortalama değerini ve standart sapma değerlerini ifade etmektedir. Z-Score Normalizasyonu, herhangi bir özellik çıkarımı yapılmış CSV dosyasındaki verilere uygulandığında, 5 farklı özellik çıkarımı ve her bir eksen (X, Y, Z) verisi için hesaplandığında eksen başına 5 olmak üzere toplamda 15 adet standardize edilmiş özellik ortaya çıkmaktadır. Bu 15 adet standardize edilmiş olan veri sonrasında model eğitimi ve testleri için FFNN tipinde yapılmasına karar verilmiş ANN’nin giriş katmanını oluşturmaktadır.

4.2.3. İleri yönlü yapay sinir ağı (FFNN)

Z-Score Normalizasyonu sonucunda standardize edilmiş verilerin AI kullanılarak eğitilmesine ve testlerinin yapılmasına karar verildikten sonra ilgili uygulama için kullanılabilecek algoritmalar araştırılmıştır. Titreşim verileri ile yapılması planlanan çalışma, aynı bir önceki çalışmada olduğu gibi bir sınıflandırma problemidir. Bunun sebebi kullanılacak yöntem sonucunda iki sonucun üretilmesi ve pervanelerin hasarlı veya hasarsız olarak sınıflandırılıyor olmasıdır. Daha önce de bahsedildiği üzere, sınıflandırma problemleri için literatürde tercih edilen yöntemler genel olarak SVM, KNN, Random Forest, Gradient Boosting, NG Boosting, Sinir Ağları, DT, Naive Bayes, Fuzzy Logic, ARIMA veya LSTM ve bunların farklı varyantlarıdır.

Akustik diyagnostik uygulamasında da belirtildiği üzere, Gradient Boosting, NG Boost veya SVM yöntemleri verileri işleme şekillerine bağlı olarak diğerlerinden daha yavaş çalışabilmektedir. Bu nedenle bu çalışmada da tercih edilmemişlerdir.

Random Forest yöntemi oldukça etkili bir yöntem olsa da, akustik diagnostik uygulaması altında kullanıldığı için benzer bir sınıflandırma problemi için tekrar kullanılması tercih edilmemiştir.

Akustik diyagnostik uygulama kısmında ANN kullanılması düşünülmüş, ancak verilerin az olması sebebi ile tercih edilmemiştir. Ancak bu çalışma içerisinde 1.000.000 satıra yakın veri olmasından dolayı tekrar değerlendirilmiş ve çalışmanın bu yöntem ile yapılmasına karar verilmiştir. Toplanan verilerin %80'i model eğitimi ve %20'si modelin doğrulanması aşamalarında kullanılmıştır.


ANN'in literatür içerisinde çeşitli yerde kullanılan farklı varyantları mevcuttur. Bu varyantlardan en çok kullanılanlarından bazıları, RNN, CNN ve FFNN'dir. Bu yöntemler içerisinde FFNN ile ilerlenilmesi uygun görülmüştür. Bunun sebebi, her ne kadar FFNN yöntemi RNN veya CNN kadar güçlü olmasa da eğitim esnasında modelin basit bir şekilde eğitilebiliyor olması, işlem gücü bakımından daha az kaynak ile etkili bir şekilde çalışabiliyor olması ve basitliği nedeni ile tercih edilmiştir.

Kullanım kolaylığı olarak bakıldığında zaman, RNN veya CNN tiplerindeki ANN'ler isimlerini katmanlarında bulunan nöronlardaki bilgi akışının yönleri ile almışlardır. Bir RNN hem ileri hem de geri yönlü olmak üzere bilgi sağlayan ve sonsuz impuls olarak adlandırılan bir döngü ile iki yönlü çalışmaktadır. CNN ise RNN'ye benzemekle birlikte sonlu bir impuls değerine sahiptir. Her iki yöntemin de gerek bağlantı şekilleri gerekse de katmanları bu yöntemlere karmaşıklık katmaktadır. Ayrıca CNN'in en önemli

özelliklerinden biri görüntü ve resimleri yüksek doğrulukla işleme yeteneğidir. Görüntü ve resim gibi dosyaların dışında işlem yapıldığında etkinliklerinin bir kısmını kaybetmektedirler.

Diğer yandan, FFNN'nin temel makine öğrenmesi çalışmalarında yaygın olarak kullanılıyor olması ve özellikle model eğitimi öncesinde özellik çıkarım teknikleri uygulanmış veriler ile etkili bir şekilde çalışabiliyor olması bu yöntemin tercih edilmesindeki diğer sebeplerdir.

Kullanılacak yönteme karar verildikten sonra, titreşime bağlı veriler ile yapılması planlanan diyagnostik uygulama için FFNN kurulmuştur (Şekil 4.3).



Şekil 4.3. Model eğitiminde kullanılan FFNN

Yaratılmış olan mimariye genel olarak bakıldığında, giriş katmanı, gizli katmanlar ve çıkış katmanından oluştuğu görülmektedir.

Giriş katmanı, Z-Score Normalizasyonu yapılmış olan ve her CSV dosyasındaki 3 sütun için toplamda 15 veriden oluşan veri setinin yapay sinir ağına girdiği katmandır. Bu nedenle toplamda 15 nörondan oluşmaktadır.

Gizli katman tarafı, giriş verilerinin anlamlı özelliklerini bir karar mekanizması olarak kullanarak çıkışa veren katmanlardır. Şekil 4.3’de gizli katmanlar kolay anlaşılabilmesi için “Dense Layer” ve “Dropout Layer” olarak ayrı şekilde çizilmiştir. Normalde, “Dropout” bir katman değil, “Dense Layer” olarak adlandırılan gizli katmanda kullanılan bir özelliktir. Buna göre şekilde toplamda iki gizli katman olduğu söylenebilir. Birinci gizli katmanda 128 nöron kullanılmıştır. Bu 128 nöronun her biri kendisinden sonra gelen 64 nöronun her birine bağlıdır. Kullanılacak nöron sayısını fazla tutmak model eğitimi esnasında aşırı uyum denen duruma sebep olacak ve bu durumda ANN, tüm eğitim seti ile birlikte içerisindeki en ufak farklılıklara karşı dahi hassas olacaktır. Diğer yandan, çok az nöron kullanılması durumunda ise az uyum denilen durum oluşacak ve eğitim ve test aşamalarında sonuçlar tatmin edici olmayacaktır. Çalışma esnasında 64, 128, 256 nörona sahip gizli katmanlar denenmiş ve en uygun olarak birinci gizli katmanda 128, ikinci gizli katmanda 64 nöronun kullanılmasının iyi sonuçlar verdiği tespit edilmiştir.

İlgili şekilde “Dropout” olarak bahsedilen özellik, FFNN tipi bir ağda sıklıkla kullanılan ve eğitim esnasında modelin aşırı uyum durumlarından kaçınmasını sağlayan bir özelliktir. Bu özellik program içerisinde “0.5” olarak belirtilmiş olup, eğitim esnasında, rastgele olarak belirlenmiş toplam nöron sayısının %50’si kadar nöronun değerlerini sıfırlayan ve dolayısıyla ilgili gizli katmandan geri kalan %50’lik nöronun kullanılarak verinin ileri yönlü akmasını sağlayan bir özelliktir. Dropout yüzdesi eğitim esnasında değişmemekle birlikte, nöronların yarısı her iterasyonda yeniden rastgele olarak seçilmektedir.

ANN’leri lineer regrasyondan ayıran en önemli özelliklerinden bir tanesi lineersizlik durumları gösterebilmeleridir. Bu durumun sağlanabilmesinin en önemli adımlarından biri ANN içerisinde kullanılan aktivasyon fonksiyonu (Activation Function) denilen bileşendir. Bir aktivasyon fonksiyonu, ilgili nöronun çıkışının 0 olup olmayacağına karar vererek ilgili ANN’in verilerden öğrenebilmesini ve karmaşık veriler ile baş edebilmesini sağlar. Eğitilmiş model içerisinde, aktivasyon fonksiyonu olarak Rektifiye Lineer Birim (ReLU) kullanılmıştır.

ReLU, derin öğrenme ile ilgili bir çok çalışmada yaygın bir şekilde kullanılmaktadır. Denklem 4.9’da bulunan, ReLU fonksiyonunun en temel gösterimine göre, bu fonksiyon ile nöron kendisine gelen değeri eğer pozitif ise doğrudan ileri yönlü geçirecek, ancak negatif işaretli ise çıkışına 0 değerini verecektir.

$$ReLU(x) = \max(0, x) \quad (4.9)$$

Eğitilmiş olan FFNN içerisinde ReLU aktivasyon fonksiyonu kullanılmasının en büyük nedenlerinden bir diğeri, aktivasyon fonksiyonunun karar vermesi için kullanılan eşik değerin 0 olması, ve bu durumun diğ er aktivasyon fonksiyonları olan tanh veya sigmoid gibi aktivasyon fonksiyonlarına göre hesaplama hızı bakımından bir avantaj sağlıyor olmasıdır.

Yapay sinir ağının eğitimi esnasında, eğitilmiş olan modelin ne doğrulukta karar verdiğinin ve hata miktarının hesaplanması ve bu hatanın azaltılması gerekmektedir. Bunun için “optimizer” olarak da bilinen bir Kayıp Fonksiyonunun (Loss Function) kullanılması gerekmektedir. Kullanılan kayıp fonksiyonunun özellikleri genel olarak değişebilse de, temel amacı model performansını arttırmak için katsayıların (Weights) ayarlanmasını sağlamaktır. Geliştirilmiş olan ANN içerisinde kayıp fonksiyonu olarak Uyarlanabilir Moment Tahmini (ADAM) kullanılmıştır. Optimizer olarak ADAM seçilmesinin en büyük sebeplerinden biri işlem gücü anlamında verimli olması ve yapılan çalışma içerisindeki titreşim verilerinin lineer olmamasıdır.

Eğitim esnasında Epoch olarak 50 değeri kullanılmıştır. Epoch için, tüm verinin ANN üzerinde kaç kere iteratif bir şekilde kullanılacağıdır denilebilir. Epoch sayısını fazla tutmak aşırı uyuma sebep olacağından, fine-tuning esnasında 50 olarak bırakılmıştır. Bir diğ er parametre olan “Batch_size” ise 32 olarak kullanılmıştır. Batch_size parametresi tek bir iterasyon esnasında toplam verinin ne kadarının gruplarla kullanılacağını gösteren bir parametredir. Batch_size katsayıların ayarlanma zamanlarını etkilediğ inden dolayı önemlidir.

Şekil 4.3’de verilmiş olan FFNN’nin son katmanı olan çıkış katmanında aktivasyon fonksiyonu olarak “Softmax” kullanılmıştır. Bu aktivasyon fonksiyonu gizli katmandan gelen işlenmemiş çıktıları olasılıklara dönüştüren ve bunu çıkışına bir vektör olarak sağlayan bir fonksiyondur (Denkle m 4.10). Softmax; n toplam veri, x_i verideki işlenmemiş veri ve i ilgili veri olmak üzere şu şekilde ifade edilmektedir:

$$s(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (4.10)$$

Bu duruma bir örnek vermek gerekirse, çıkış katmanına gelen verinin [2.0, 1.0] olduğ u durumda, normalizasyon sonucu Denkle m 4.11 – 4.15 ile görüleb ilir;

$$e^{2.0} = 7.389 \quad (4.11)$$

$$e^{1.0} = 2.718 \quad (4.12)$$

olarak bulunur. Buna göre, bu iki sınıflandırma sonucunun toplamı:

$$7.389 + 2.718 = 10.107 \quad (4.13)$$

olacaktır. Normalizasyon sonucunda ise, olasılık değerleri:

$$\text{softmax}(2.0) = \frac{7.389}{10.107} = 0.731 \quad (4.14)$$

$$\text{softmax}(1.0) = \frac{2.718}{10.107} = 0.269 \quad (4.15)$$

olarak belirlenecektir. Bu durumda çıkış değerleri [0.731, 0.269] olup, bu değere bağlı olarak FFNN modeli, 1. numaralı durumun doğruluğundan %73.1 emindir.

Titreşim verilerinin hepsi ile FFNN modelinin eğitimi ve validasyon süreçleri tamamlanmış [EK-13], oluşturulan modelin sonrasında kullanılması için ilgili kod yazılmıştır [EK-14]. Önerilen FFNN modelinin, titreşim sensörü tarafından kayıt edilmiş veriler ile eğitildikten sonra elde edilen sonuçlar bulgular kısmında değerlendirilmiştir.

5. TOPLULUK ÖĞRENMESİ MODELİ İLE AKILLI ALGILAMA

Tez çalışması içerisinde daha önce geliştirilmiş olan diyagnostik uygulamalarda, ilk aşamada pervane tarafından alınan ses kayıtlarına MFCC ile özellik çıkarımı yapılmış, Random Forest metodu ile bir makine öğrenmesi modeli oluşturulmuş ve bu modelin %99.95 doğruluk ile hasarlı ve hasarsız pervaneleri ayırt edebildiği bulunmuştur.

İkinci aşamada ise, aynı pervaneler ile aynı süre boyunca ADXL345 titreşim sensörü kullanılarak titreşim verileri kayıt edilmiş, bu verilerde istatistiksel özellik çıkarımlarından (Mean, Median, Standard Deviation, Skewness, Kurtosis) faydalanılmış, sonrasında her bir CSV dosyasında bulunan sütun için bu özellik çıkarımlarından oluşan değerlere Z-Score normalizasyonu uygulanarak FFNN yapay sinir ağı kullanılarak eğitilmiş ve hasarlı ve hasarsız pervaneleri ayırt etmede %97.22 doğruluk ile çalışmıştır.

Bu durum sonucunda hem akustik hem de titreşim verileri ile iki farklı modelde tatmin edici sonuçlar elde edilmiştir.

Tez çalışmasının son aşamasında ise, önceki iki aşamada kullanılmış olan tekniklerin birleştirilmesi, tahmin çıktılarının ayrı bir makine öğrenmesi modelinin eğitiminde kullanılması ve bu sayede daha yüksek doğruluk elde edilmesi hedeflenmiştir. Kullanılması düşünülen bu yöntem, literatürde Topluluk Öğrenmesi (Ensemble Learning) olarak adlandırılmaktadır.

Topluluk öğrenmesi, iki farklı AI modelindeki veriler ile yapılan tahminler sonucu elde edilmiş çıktıların başka bir AI modeli içerisinde kullanılması, bu sayede tek başına kullanılan herhangi bir AI modelinden daha başarılı sonuçlar elde edilmesinde kullanılan bir tekniktir [102, 103]. Makine öğrenmesinde eğitim esnasında hatalar gözlemlendiğinde, toplam hatanın zaman içerisinde azaldığı ve sonrasında model karmaşıklığı artmaya devam ettiğinde yükselmeye başladığı söylenebilir. Bu noktada varyans ve bias terimleri önem arz etmektedir.

Bias, aşılması istenen problemlerdeki bir hata olarak tanımlanabilir. Model içerisinde yüksek bias olması modelin fazla basit olduğunu ve eğitim veya validasyon veri setlerindeki örüntüleri anlamada sorunlar yaşandığını gösterir.

Varyans ise eğitim verisindeki ufak değişikliklere karşı modelin ne kadar dayanıklı ve sağlam olduğunu, model doğrulunun ne kadar etkilendiğini belirtir. Yüksek varyans durumunda modelin karmaşıklığının oldukça fazla olduğu anlamına gelir. Bu durum, modelin performans değerlendirmeleri esnasında aşırı uyum olarak ortaya çıkar ve modelin eğitim verisi üzerinde yüksek doğrulukla çalıştığını ancak test verisi olarak

kullanılan validasyon sürecindeki verilerde başarısının düşük olacağını gösterir. İdeal şartlar altında, geliştirilmiş bir model hem varyansının hem bias 'ının düşük olması istenir ve geliştirilmiş olan uygulamalarda bu ideale yaklaşılmaya çalışılır.

Topluluk öğrenmesi konusu, AI konusunda yapılan çalışmaların konusu özelinde birkaç başlık altında toplanabilir. Bunlar, denetimli topluluk sınıflandırması, yarı-denetimli topluluk sınıflandırması, kümelemeli topluluk ve yarı-denetimli kümelemeli topluluk olarak adlandırılmaktadır. Çalışma içerisinde kullanılan Random Forest ve FNNN yöntemleri ile iki durumlu (Hasarlı ve Hasarsız) bir sınıflandırma sorunu çözülmeye çalışılmıştır. Bunun neden hasarlı ve hasarsız pervalerin 0 ve 1 olarak etiketlenmesidir. Dolayısıyla, bu iki yöntemin çıktılarını giriş değeri olarak kullanacak bir topluluk öğrenmesi bir denetimli topluluk sınıflandırması olacaktır. Bu denetimli topluluk sınıflandırması sonucunda tahmin verileri oylanarak son tahmin verisi elde edilecektir.


Topluluk öğrenmesi ile yapılacak olan çalışmada, akustik diagnostik çalışmasında avantajlarından bahsedilmiş olan, aşırı uyum durumlarına karşı dayanıklı, titreşim ve akustik gibi farklı özellik uzaylarına sahip kümeler ile etkili olarak çalışabilen ve olasılık tahminlerinin kombinasyonları ile çalışabilen Random Forest yöntemi seçilmiştir.

5.1. Yöntem

Kullanılan topluluk öğrenmesi yönteminde, akustik diagnostik kısmında MFCC özellik çıkarımı sonrasında kadar tüm süreç ve kullanılan akustik veriler ilgili çalışmadaki yöntem ile aynıdır. Akustik diyagnostik uygulamasından tek farkı, MFCC ile özellik çıkarımı yapılan verilerin aynı titreşim diyagnostik uygulamasında olduğu gibi Z-Score normalizasyonu yöntemi ile standardize edilmiş olmasıdır. Titreşim diyagnostik uygulamasının yöntem bölümü içerisinde Z-Score Standardizasyonunun kullanım amacının ve model eğitime yaptığı olumlu etki dışında, topluluk öğrenmesi içerisinde titreşim verileri ve akustik veriler ile eğilecek Random Forest'ın girişine aynı ölçekteki verilerin verilmesi modelin çalışmasına ve sonuçlarına olumlu katkı yapacağı düşünüldüğünden ötürü, MFCC sonrasında Random Forest ile henüz veriler eğilmeden standardize edilmiştir.

Titreşim verileri ise daha önce “Yapay Sinir Ağı ile Titreşime Bağlı Diyagnostik” başlığındaki veriler olup, yine aynı veri seti ile tüm adımlar şekilde gerçekleştirilerek

FFNN yapay sinir ağının eğitimi tamamlanmıştır. Akıllı algılama eğitim akışı Şekil 5.1’de gösterilmiştir.



Şekil 5.1. Akıllı algılama eğitim akışı

Her iki modelin de eğitimi önceki çalışmalara benzer şekilde tamamlandıktan sonra validasyon durumuna geçilmiştir. Validasyon dosya sayısı akustik veriler için 60 farklı CSV dosyasıdır. Titreşim verilerinde ise dosya sayısı olarak 5 farklı pervaneye ve 3 farklı itki durumuna ait toplamda 300 adet CSV dosyası bulunmaktadır. Topluluk öğrenmesi için kullanılacak Random Forest yönteminde, akustik veriler ile eğitilmiş Random Forest algoritmasının validasyon çıktıları ile FFNN algoritmasının çıktılarının kombinasyonu kullanılmaktadır. Bu kombinasyonun sorunsuz şekilde yapılabilmesi için her iki tarafın da validasyon esnasında kullanılan veri uzayının aynı boyutta olması gerekmektedir. Bu nedenle, hasarlı pervaneye ait titreşim verilerinde bulunan 300 dosyanın 60 tanesinin alınması gerekmektedir. Bu 60 adet dosyayı sıralı şekilde almak model doğruluğu açısından olumsuz bir durum oluşturacağı için, 60 dosyanın seçiliminin rastgele yapılması uygun görülmüştür.

Son adımda, akustik model ve titreşim modeli ayrı şekilde tahminler yapmış, bu tahminler kombine edilerek topluluk öğrenmesi için kullanılan Random Forest modelinin eğitimi tamamlanmış ve sonrasında validasyon verileri kullanılarak model performansları ölçülmüştür [EK-15]. Ayrıca kayıt edilen model dosyalarının tekrar kullanılması için

gerekli kodlama da yapılmıştır [EK-16]. Yapılan ölçümler sonucunda yüksek başarı elde edilmiştir.



6. BULGULAR

Random Forest veya başka bir yaklaşım ile geliştirilmiş tüm AI uygulamalarının bir validasyon sürecinden geçerek test edilmesi ve test sonuçlarına dayalı olarak ilgili modelin performansının değerlendirilmesi çeşitli nedenlerden dolayı önem arz etmektedir.

İlk olarak, AI modelinin eğitim esnasında karşılaşmadığı, görülmemiş verilerle ilgili bir değerlendirme sağlamaktadır. Herhangi bir AI tabanlı bir modelin asıl hedefinin gerçek şartlar altında iyi performans göstermesi olduğu düşünülürse, bu değerlendirme ile modelin eğitilmiş veriler haricinde ne kadar doğru tahmin yapabildiği ortaya konur.


Bunun dışında, değerlendirme sonrasındaki veriler izlenerek, modelin performansı ile ilgili bir problem varsa hangi noktaların ince ayarlarının (Hyperparameter Fine Tuning) yapılması gerektiği hakkında fikir verir. İyileştirmesi gereken alanlar belirlendikten sonra, ilgili alanların hiperparametrelerinin ayarlanması modelin daha iyi sonuç vermesini salayabilir. Modelin performansı değerlendirildikten sonra eğer performans ile ilgili sorunlar varsa, bu noktada ilgili hiperparametrelerin ayarlanması dikkatli bir şekilde yapılmalıdır. Random Forest gibi ağaç tabanlı bir algorithmada doğru tahmin yüzdesini yukarı çekmek için kullanılabilecek tahminci veya maksimum derinlik gibi hiperparametreler model başarısını önemli ölçüde etkileyebileceği gibi aynı zamanda işlem süresini de uzatarak özellikle on-board sistemler üzerindeki çalışma performansını kötü bir şekilde etkileyebilir veya eğitim verilerinin “Underfit” veya “Overfit” olmasına neden olabilir. Tüm bu sebeplerden dolayı eğitilmiş bir modelin başarısının değerlendirilmesi önemlidir.

Daha önce bahsedildiği üzere, Random Forest kullanılarak eğitilen AI modeli başarılı sonuçlar vermiştir. Model başarısı ile ilgili bulgular aşağıdaki bölümlerde yer almaktadır.

6.1. Akustik Diyagnostik


Geliştirilmiş AI modeli test edilirken, kullanılan MFCC sonucunda hangi özelliklerin (Features) modelin tahmininde daha fazla payı olduğunu belirlemek için FI'dan yararlanılmıştır (Şekil 6.1). Daha önce belirtildiği üzere, MFCC özellik çıkarımı sonrasında CSV dosyasında 20 sütun bulunmaktadır. Random Forest ile eğitilmiş AI

modelinin, bu sütunlardan özellikle sırasıyla 0, 3, 2 ve 1 numaralı sütunları kullanarak başarılı tahminler yaptığı görülmektedir.




Şekil 6.1. AI modelin FI değerlendirme sonuçları

Bir diğer performans göstergesi ROC grafiğidir. Testleri yapılmış olan AI modelinin ROC grafiği Şekil 6.2’de verilmiştir. Grafikte bulunan çapraz çizgi (rastgele tahmin çizgisi) genellikle ROC eğrilerinde temel çizgi olarak kullanılır ve örnekleri pozitif veya negatif olarak sınıflandırma şansı eşit olan rastgele bir sınıflandırıcının performansını temsil etmektedir. ROC değeri 0 ile 1 arasında değişmektedir. Çizgi 1’e ne kadar yakın olursa AI modeli o kadar iyi sonuç vermiş ve %100 doğruluğa ulaşmış demektir. Yapılan ROC analizi sonrasında, geliştirilmiş olan AI modelinin ROC çizgisi neredeyse 1 çıkmıştır. Bu durum da modelin başarısını destekleyen bir grafik olduğunu göstermektedir.



Şekil 6.2. AI modelin ROC değerlendirme sonuçları

Random Forest kullanılarak yapılmış olan akustik diyagnostik uygulamasında kullanılan bir başka performans göstergesi karmaşıklık matrisi olmuştur (Şekil 6.3). Karmaşıklık matrisi, hangi verilerin gerçekten doğru bir şekilde sınıflandırıldığının bir ölçüsünü vermekte ve bu nedenle performans metrikleri içerisinde önemli bir yeri bulunmaktadır.



Şekil 6.3. AI modelin karmaşıklık matrisi değerlendirme sonuçları

Çalışmada kullanılan AI modelinin karmaşıklık matrisi sonuçları aynı zamanda modelin başarı oranını da göstermekte olduğu için ayrıca önemlidir. Şekil 6.3'den de hesaplanabileceği üzere başarı oranı %99.9651(25860 veride 25851 doğru tahmin) ile

%99.9342(25860 veride 25843 doğru tahmin) arasında değişmekle birlikte ortalama olarak yaklaşık %99.96 oranında doğru sonuçlara ulaşılmıştır.

Bu sonuçlar ile birlikte pervane akustiği konusunda yapılan AI destekli diagnostik çalışmanın sonuçlarının hasarlı ve hasarsız pervaneleri başarılı bir şekilde ayırt edebildiği ve oldukça yüksek doğrulukta çalıştığı söylenebilir.

6.2. Titreşime Bağlı Diyagnostik

Tez çalışmasının ilgili bölümü içerisinde, hasarlı pervanelerin titreşim verilerine bağlı olarak tespit edilerek bir diyagnostik uygulaması geliştirilmiştir. Bu diyagnostik uygulamasında bir ANN türü olan FFNN kullanılmıştır. AI kullanılarak geliştirilmiş uygulamalarda, model eğitimi tamamlandıktan sonra modelin başarısının analiz edilmesi ve değerlendirilmesi gerekmektedir. Bu değerlendirme sonucunda modelin öğrendiği verilerden başka, aşına olmadığı verilere nasıl tepki verdiği ve ne kadarını doğru bir şekilde tahmin edebildiğinin ölçülmesi amaçlanmaktadır.

Ayrıca model eğitiminin sonucundaki validasyon süreci, model doğruluğunun artırılması için gerekli hiperparametre ayarlarının yapılarak (Fine-tuning) modelin daha iyi sonuçlar vermesini sağlamaktadır. Geliştirilmiş olan titreşim diagnostik uygulamasında da özellikle nöron sayısı ve dropout miktarları bu hiperparametre ayarlama süreci içerisinde değerlendirilerek son durumlarına getirilmiş ve sonra çeşitli performans metrikleri kullanılarak modelin başarısı ölçülmüştür. Bu şekilde hem daha yüksek doğrulukta bir model elde edilmiş hem de aşırı ve az uyum durumlarının önüne geçilmeye çalışılmıştır.

Akustik diyagnostik uygulamasında da uygulanan yöntemle benzer şekilde, model başarı sonuçlarını değerlendirmek için farklı yöntemler kullanılmıştır. Bunlar; Karmaşıklık Matrisi ve ROC'dir.


Modelin başarı değerlendirmesinde öncelikle karmaşıklık matrisinden faydalanılmıştır. Akustik diyagnostik uygulamasında da belirtildiği üzere karmaşıklık matrisi, sınıflandırma için kullanılan bir AI modelinin başarısını değerlendirmede kullanılan bir yöntemdir. Model içerisindeki veri setinin TP, FP, TN ve FN taraflarına odaklanır.

Modelin çalışma performansı için doğrudan bir gösterge sunduğu için karmaşıklık matrisi gösteriminden faydalanılmıştır. Bu nedenle, hasarlı pervanelerin titreşime bağlı

diyagnostiği uygulaması içerisinde kullanılan ANN tabanlı FFNN AI modeli için de bir karmaşıklık matrisi oluşturulmuştur.

Yapılan çalışma içerisinde toplamda 918.000 satır veri bulunmaktadır. Bu verilerin toplam 765.000 satırı hasarlı pervaneye aittir. Hasarlı pervane ait 765.000 satır verinin %20'si, yani 153.000 satır veri modelin validasyonu için kullanılmıştır. Benzer şekilde, 153.000 hasarsız pervane verisinin yine %20'si, yani 30.600 tanesi validasyon için kullanılmıştır. Titreşim verilerinin aynı akustik diyagnostikte olduğu gibi yaklaşık 17 dakika boyunca kaydedildiği ve kullanılan titreşim sensörünün 50Hz frekans ile çalıştığı göz önüne alındığında, her bir CSV dosyasında 510 adet veri bulunmakla birlikte, toplamda her bir pervanenin her bir itki durumu için 80 adet eğitim, 20 adedi validasyon olmak üzere toplamda 100 CSV dosyası ve 51.000 satır veri kullanılmıştır.

FFNN ile yapılmış olan diyagnostik uygulamada, yöntem kısmında da belirtildiği üzere CSV dosyalarında bulunan ve X,Y ve Z eksenlerindeki titreşimlere karşılık gelen her bir sütuna istatistiksel özellik çıkarımı yöntemleri ile özellik çıkarımı yapılmıştır. Dolayısıyla her bir hasarlı pervanenin validasyonu için kullanılan ve %20'lik dilime karşılık gelen 20 CSV dosyasından, 20 adet içerisinde ve içerisinde X,Y,Z koordinat bileşenlerine ait Z-Score standardize edilmiş verileri içeren dosya eğitime dahil edilmiştir. Bu durum sonucunda 3 itki miktarı için hasarlı ve hasarsız pervane başına 60 adet dosya ile işlem yapılmıştır. Hasarlı pervane sayısı 5 adet olduğu için, hasarlı pervane kategorisinde 300, hasarsız pervane kategorisinde ise 60 adet titreşim vektörü bulunmaktadır. Oluşturulmuş olan karmaşıklık matrisi tablosunda da bu durum açık bir şekilde görülmektedir (Şekil 6.4).



Şekil 6.4. FFNN modelinin karmaşıklık matrisi değerlendirme sonuçları

Karmaşıklık matrisine ait tabloda sonuçların tüm detayları görülmektedir. FFNN validasyonu esnasında modelin sınıflandırmış veriler doğruluk durumlarına göre sınıflandırılmıştır. Burada bulunan 298 değer gerçekten hasarlı pervaneye ait olup, FFNN tarafından hasarlı olarak değerlendirilmiştir (TP). 52 değer gerçekten hasarsız pervaneye ait olup, FFNN tarafından hasarsız olarak değerlendirilmiştir (TN). 8 değer hasarsız pervaneye ait olup, FFNN tarafından hasarlı olarak değerlendirilmiştir (FP). 2 değer ise hasarlı pervaneye ait olup, FFNN tarafından hasarsız olarak değerlendirilmiştir (FN).

Şekilde görülen değerler, modelin başarısını ölçmede etkin bir şekilde kullanılmaktadır. Bu değerler göz önüne alınarak FFNN'nin başarısını ortaya koyan Accuracy, Precision, Recall, F-1 Skoru hesaplanmıştır.

Hesaplanan performans metriklerinden ilki olan Accuracy, modelin ne doğruluk ile çalıştığını gösteren temel performans metriklerinden biridir. Hesaplanması Denklem 3.12 kullanılarak ve Denklem 6.1'de gösterildiği şekilde hesaplanmaktadır.

$$Accuracy = \frac{298+52}{298+52+8+2} = \frac{350}{360} = 0.972 = \%97.20 \quad (6.1)$$

Performansın ölçülmesinde kullanılan diğer bir özellik olan Precision, tüm doğru olarak sınıflandırılan tahminler içerisinde gerçekten doğru tahmin edilen hasarlı pervanelerin oranını vermektedir. Precision, Denklem 3.11 kullanılarak ve Denklem 6.2'de gösterildiği gibi hesaplanmaktadır.

$$Precision = \frac{298}{298+8} = \frac{298}{306} = 0.974 = \%97.40 \quad (6.2)$$

Performans metrikleri içerisinde yer alan ve diğer önemli bir gösterim olan Recall(Sensitivity veya TPR) doğru bir şekilde pozitif olarak sınıflandırılmış olan değerlerin tüm gerçekten doğru sınıflandırılmış değerlere oranlanması ile bulunmakta ve Denklem 3.9 kullanılarak ve Denklem 6.3’de gösterildiği gibi hesaplanmaktadır.

$$Recall = \frac{298}{298+2} = \frac{298}{300} = 0.9930 = \%99.30 \quad (6.3)$$

Model performansını gösteren performans metriklerinin sonuncusu olan F1 Skoru ise, precision ve recall değerlerinin ortalaması olup her iki değer denge durumunu göstermekte ve Denklem 3.13 kullanılarak ve Denklem 6.4’de gösterildiği gibi hesaplanmaktadır.


$$F1\ Score = 2 * \frac{0.974*0.993}{0.974+0.993} = 0.983 = \%98.30 \quad (6.4)$$

Modelin performans değerlendirmesi sonucunda recall değerinin %99.30 çıkması, FFNN’in neredeyse tüm hasarlı pervaneleri doğru bir şekilde tanımlayabildiğini göstermektedir. Precision değerinin %97.40 olarak bulunması, tahminlerdeki gerçekten hasarlı pervanelerin oranını göstermektedir ve hasarlı olarak tahmin edilmiş tüm tahminlerin ne kadarının gerçekten hasarlı olduğu belirtmektedir. F1 Skorunun %98.3 çıkması, precision ve recall arasındaki denkenin iyi olduğunu ve model tahminlerinin güvenilir olduğunu göstermektedir. Accuracy değerinin %97.20 olarak hesaplanması ise, geliştirilmiş olan FFNN’nin veriler ile iyi bir şekilde eğitildiğini ve tahmin doğruluğunun oldukça yüksek olduğunu göstermektedir.

ROC, akustik diyagnostik uygulaması içerisinde de açıklandığı üzere, TP ve FP durumları arasındaki ilişkiyi göstermekte ve model başarısı hakkında bilgi vermektedir. ROC’nin gösterilmesi ve model başarısının değerlendirilmesi esnasında AUC skoru belirleyici olmaktadır.

ROC eğrisi temel olarak, akustik diyagnostik çalışması esnasında belirtildiği gibi TPR ve FPR değerlerinin çizildiği bir eğridir. AUC parametresi, FFNN’nin hasarlı ve hasarsız olarak nitelendirilen iki durumlu koşulların ne kadar iyi bir şekilde birbirlerinden ayırt edilebildiğini göstermekte ve 0 ile 1 değerleri arasında değişmektedir. Geliştirilmiş olan FFNN uygulaması içerisinde AUC 0.99 olarak bulunmuş olup, modelin yüksek bir

TPR değerine ve düşük bir FPR değerine sahip olduğunu, dolayısıyla çok iyi bir performans sergilediğini belirtmektedir (Şekil 6.5).



Şekil 6.5. AI modelin ROC değerlendirme sonuçları

FFNN modelinin performans değerlendirmeleri sonucunda elde edilmiş olan performans metrikleri, titreşime bağlı diyagnostik uygulamasının çalışma sonuçlarının %97.20 gibi oldukça yüksek doğrulukta olduğunu göstermektedir.

Tez çalışmasının devamında, akustik değerler ve titreşim değerlerinin birlikte aynı modelin eğitiminde kullanılması ve bu sayede model doğruluk yüzdelerinin daha yukarı çıkarılması hedeflenmiştir.


6.3. Akıllı Algılama

Topluluk öğrenmesi yöntemi ile geliştirilmiş olan akıllı algılama modelinin sonuçları, hem titreşim model performansı, hem akustik model performansı hem de topluluk öğrenmesi performansı olarak ayrı ayrı incelenmiştir. Bunun nedeni, akustik modeli içine Z-Score Normalizasyonunun katılması ve titreşim modeli içerisinde hasarlı pervanenin validasyon miktarının kısıtlanması sonucu model başarı oranlarının az da olsa değişiklik göstermesidir.


6.3.1. Akustik model performansı

Önceden yapılan akustik diagnostik çalışmasında yüksek doğruluk elde edilmiştir. İlgili çalışmada Random Forest algoritmasının Accuracy değeri %99.95 olarak, Precision Değeri %99.96 olarak, Recall değeri %99.93 olarak ve F1 Skoru ise %99.95 olarak hesaplanmıştır.

Topluluk öğrenmesi içerisinde, daha önce de bahsedildiği üzere, veriler MFCC özellik çıkarımından çıktıktan sonra Random Forest algoritması ile eğitilmeden veya validasyon süreci yapılmadan önce Z-Score Normalizasyonu yapılmıştır. Bunun sonucunda oluşan karmaşıklık matrisi ve ROC performans metriği aşağıdaki gibidir (Şekil 6.6, Şekil 6.7).



Şekil 6.6. Z-Score normalizasyonu sonrası akustik verilerin karmaşıklık matrisi




Şekil 6.7. Z-Score normalizasyonu sonrası akustik verilere ait ROC

Performans metriklerinden görülebileceği üzere, topluluk öğrenmesi içerisinde akustik veriler ile eğitilmiş olan Random Forest algoritmasının doğruluğu %99.95'in üzerine çıkarak %100 olmuştur. Benzer şekilde, bu modele ait Precision, Recall ve F1 Skorları da tüm sınıflandırmalar doğru bir şekilde yapıldığı için %100'dür. Z-Score Normalizasyonun model eğitimi içerisine dahil edilmesi sonucunda model doğruluk oranı artmıştır.


6.3.2. Titreşim modeli performansı

Topluluk öğrenmesi yöntemi öncesinde yapılmış olan ve topluluk öğrenmesinin diğer yarısını oluşturan “İleri Yönlü Yapay Sinir Ağı ile Titreşime Bağlı Diyagnostik” çalışmasının sonucunda FFNN algoritmasının Accuracy değeri daha önce de bahsedildiği üzere %97.22, Precision Değeri %97.40 olarak, Recall değeri %99.30 olarak ve F1 Skoru ise %98.30 olarak bulunmuştur.

Topluluk öğrenmesi modeli içerisinde yapılan çalışmada, daha önce de bahsedildiği üzere, hasarlı pervanelere ait validasyon dosya sayısının uygun kombinasyonu oluşturabilmek adına 60 adet CSV dosyası rastgele olarak seçilmiş ve model eğitimi ve validasyonu tamamlanmıştır. Bunun sonucunda oluşan karmaşıklık matrisi ve ROC ve AUC performans metrikleri aşağıdaki gibidir (Şekil 6.8, Şekil 6.9).



Şekil 6.8. Rastgele seçilmiş veriler ile FFNN karmaşıklık matrisi




Şekil 6.9. Rastgele seçilmiş veriler ile FFNN'ye ait ROC

Performans metriklerine bakıldığında, topluluk öğrenmesi içerisinde titreşim verileri ile eğitilmiş olan FFNN algoritmasının Accuracy değeri %97.22'nin altına düşerek %90, Precision değeri %83.30, Recall değeri %100, F1 Skoru ise %90.09 olarak (Denklem 3.12, Denklem 3.11, Denklem 3.9, Denklem 3.13) hesaplanmıştır. Validasyon


sonrasında deęerlerin önceki çalışmadan farklılık göstermesi, hasarlı pervane örneklem sayısının rastgele seçilerek sınırlandırıldığı düşünöldüğünde normaldir.

6.3.3. Topluluk öğrenmesi modeli performansı

Topluluk öğrenmesi için kullanılmış olan Random Forest algoritması hem akustik veriler için kullanılmış Random Forest algoritmasının hem de FFNN algoritmasının eğitilmesi sonrasında gelen veriler ile eğitilmiştir. Sonrasında ise validasyon setlerinin kombinasyonu ile model performans metrikleri ortaya çıkarılmıştır. Akıllı algılama çalışmasının sonucunda oluşan karmaşıklık matrisi ve ROC-AUC performans metrikleri aşağıdaki gibidir (Şekil 6.10, Şekil 6.11).



Şekil 6.10. Topluluk öğrenmesi karmaşıklık matrisi



Şekil 6.11. Topluluk öğrenmesi ROC grafiği

Birden fazla model ile eğitilen Random Forest AI modelinin performans metriklerine bakıldığında, Accuracy oranı %100, Precision oranı %100, Recall oranı %100 ve F1 Skoru %100 olarak bulunmuş ve çok yüksek bir performans elde edilmiştir. Aynı zamanda ROC ve grafiğinden görülebildiği üzere ROC çizgisi 1 üzerinde ve AUC ise 1.0 olarak oluşmuştur. Bu durum karmaşıklık matris sonucunu desteklemekte ve modelin yüksek başarı gösterdiğini belirtmektedir.

Topluluk öğrenmesi yöntemi ile, hem akustik hem titreşime bağlı verilerin birbirinden farklı iki algoritma ile model eğitimleri sonrasındaki performanslarının yukarı çıkarılması hedeflenmiş ve model validasyonu sonucunda ortaya çıkan çok yüksek doğruluk oranları ile modelin etkinliği doğrulanmıştır. Bu yaklaşım, gerçek şartlar altında insanlı hava araçlarına veya İHA'lara uygulanabilir ve farklı sensörlerin çapraz kontrolü ile yüksek doğruluk elde edilmesinde kullanılabilir.

7. SONUÇLAR

Hava araçlarının özellikle kritik sistemlerinin ve komponentlerinin sürekli olarak izlenmesi ve sistemler ile ilgili anormal durumların tespit edilmesi hem insanlı hava araçları hem de İHA'lar için literatür içerisinde de üzerinde oldukça düşünülen konulardan biridir. Hangi kritik sistem veya alt sistemin hangi noktalarına diyagnostik yaklaşımlarda bulunulabileceği konusu da literatür çalışmaları içerisinde yer almaktadır.

Yapılmış olan tez çalışmasında, özellikle araştırmacılara veya İHA konuları ile ilgilenen diğer kişilere referans olması için öncelikle bir hava aracı mimarisi geliştirilmiştir. Bu sayede araştırmacılar için sistemlerin ve alt sistemlerin birbirleri ile bağlantı şekilleri, hangi sensör veya ekipmanın ne tür gereksinimleri olabileceği ve sistem içerisinde bulunabilecek verilerin ne olduğu ortaya konmaya çalışılmıştır.

Referans mimari geliştirilirken çalışmanın sabit kanatlı bir İHA üstüne yapılmasında karar kılınmış, sistem mühendisliği kavramı araştırılmış ve çalışma içerisinde MBSE ilkeleri benimsenmiştir. Çalışmanın amaçlarından bir tanesi yapılmış olan referans mimarinin tez sonucunda açık kaynak olarak paylaşılmasıdır. Bunun sonucunda dileyen herkesin yaratılmış olan mimariden çeşitli şekillerde faydalanması amaçlanmıştır.

Hedeflenen hava aracı mimarisinin oluşturulması için topluluk desteğinin oldukça fazla olduğu ve ücretsiz kullanıma uygun Eclipse tabanlı Papyrus modelleme ortamı tercih edilmiştir. Geliştirme ortamının kurulumları ve gerekli ayarları yapıldıktan sonra SysML kullanılarak hava aracının modellenmesine başlanmıştır.

Hava aracı modelinin oluşturulmasında öncelikle program içerisinde çeşitli sistemlerin ve bu sistemlerde kullanılacak ekipmanların özellikleri göz önünde bulundurularak fiziksel büyüklükler tanımlanmıştır. Sonrasında, hava aracının oldukça fazla bileşeni ve ekipmanı olabileceği için alt sistemler yaratılmıştır. Bu alt sistemler itki sistemi, kontrol sistemi, emniyet ve alarm sistemi, uçuş kontrol sistemi, güç sistemi, sensörler ve aviyonikler olarak belirlenmiştir. Bu şekilde alt sistemler yaratılarak hem araştırmacıların genel sistem mimarisini daha iyi anlayabilmeleri hem de ilgilendikleri sistemlere ulaşmalarını basitleştirmek amaçlanmıştır.

Fiziksel büyüklüklerin tanımlanması bittikten sonra hava aracının her alt sistemi için değer tiplerinin oluşturulmasına başlanmıştır. Değer tipleri, hava aracı içerisinde kullanılan her ekipmanın ve dolayısıyla alt sistemlerin de birbirleri ile haberleşmesi esnasında ne tipte verilerin söz konusu olacağını ortaya koyan bloklardır. Bu değer tipleri

her alt sistemin her ekipmanı düşünülerek oluşturulmuş olup, bir sonraki adımda BDD diyagramlarının oluşturulmasına geçilmiştir.

SysML'nin avantajlarından bir tanesi kurulacak olan sistemlerin istenilen basitlikte veya istenildiği kadar detaylı şekilde ortaya konabilmesine olanak sağlamasıdır. Sistem modellemesi gerçekleştirilirken en genel durumdan en detaylı duruma doğru modelleme yapılması benimsenmiştir. Bunun için öncelikle bir genel sistem mimarisi oluşturulmuş ve burada tüm alt sistemler gösterilmiştir. Daha sonra bu tüm alt sistemlere ait birer tane BDD diyagramı oluşturulmuştur. Bu BDD diyagramları ilgili sistemin içerisinde bulunan ekipmanları göstermekle birlikte, oluşturulmuş her bir ekipman daha öncesinde oluşturulmuş olan veri tipleri ile ilişkilendirilmiş ve dolayısıyla bu ekipmanlardan ne tipte verilerin alınabileceği veri akışı da gösterilerek belirtilmiştir.

Bir sonraki adımda RD diyagramları oluşturulmuştur. Bu diyagramlar her bir alt sistemde bulunan ekipmanların seçilmesi ve kullanılması esnasında ihtiyaç duyulabilecek gereksinimleri açıklamalar ile birlikte göstererek geliştiricilere ve bu konuda araştırma yapacak kişilere yardımcı olmaktadır. RD diyagramlarının tamamlanmasından sonra ise BDD diyagramlarını detaylı şekilde açıklayan IBD diyagramlarının oluşturulmasına geçilmiştir.

Tüm sistemlerin ve sistem içerisindeki unsurların birbirleri ile ilişkisini ortaya koyan IBD diyagramları her sistem için ayrı bir şekilde oluşturulmuştur. Ayrıca bir genel sistem mimarisi IBD diyagramı da oluşturularak hava aracının geneline bir bakış sağlanmış ve tüm alt sistemlerin detaylarıyla birlikte hangi alt sistemler ile ilişki içerisinde olduğu belirtilmiştir.

Tez çalışmasının hava aracı modelleme kısmı ile ilgili sonra çalışmada ise UCD diyagramları oluşturulmuştur. Kullanım senaryolarını açıklayan UCD diyagramları UML dili kullanılarak oluşturulmuş ve alt sistemlerdeki aktörleri ve bu aktörlerin sistemin unsurları ile ilişkisini göstermiştir. Bu ilişkiler aynı zamanda hava aracı üzerinde yapılacak bir geliştirme veya herhangi bir uygulama için hangi alt sistemin neresine odaklanması gerektiği konusunda da yardımcı olmaktadır. Tez çalışması içerisinde kullanılmış olan diyagnostik uygulamalar da bu hava aracı mimarisinin sağlamış olduğu tüm sistemlere basitleştirilmiş bir bakış penceresinden bakılarak karar verilmiştir.

Tez çalışmasının sonraki aşamaları diyagnostik çalışmalar üzerine kurulmuştur. Bunun için öncelikle referans mimarinin içerisinde aviyonikler alt başlığında da belirtilmiş olan mikrofon esas alınarak akustiğe bağlı bir uygulama geliştirilmiştir. Bu

uygulama için öncelikle ekipmanlar seçilmiş ve test ortamı kurulmuştur. Sonrasında bir mikrofon yardımı ile, ortam gürültüsü azaltılmaya çalışılmadan hava aracın pervanesine ait ses kayıtları alınmıştır. Ses kayıtlarının alınmasındaki birincil amaç bir makine öğrenmesi metodu ile hasarlı ve hasarsız pervanelerin sınıflandırılması olmuştur. Bunun için beş farklı hasar tipi belirlenmiş ve beş özdeş pervaneye kesme, çentik atma ve yontma şekillerinde hasarlar verilmiştir. Bir pervane ise hasarsız durumda bırakılmıştır. Bir sonraki adımda, akustik kayıtlara veriler arasındaki ilişkilerin daha iyi anlaşılabilmesi için özellik çıkarım tekniği uygulanmıştır. Literatür içerisinde geçen ve akustik ile ilgili oldukça yaygın kullanımı olan özellik çıkarım tekniklerinden biri MFCC tekniğidir. Bu teknik ile ses kayıtlarının frekans özellikleri çıkarılarak etkin bir makine öğrenmesi amaçlanmıştır. Son adımda ise karar ağacı tabanlı olan Random Forest metodu bu veriler ile eğitilmiş ve bunun sonucunda %99.96 doğruluk oranı yakalanmıştır.

Akustik diyagnostik uygulaması tamamlandıktan sonra, aynı pervaneler kullanılarak başka bir yöntem ile akustik diyagnostik uygulamasının desteklenmesi amaçlanmıştır. Bunun için, itki sisteminin kritik ekipmanlarından bir diğeri olan motorun üzerine yerleştirilmiş bir IMU sensörü kullanılarak titreşim verilerine dayanarak pervane hasarının belirlenmesi konusunda çalışmalar yapılmıştır. Bu çalışma için, öncelikle hem çalışma frekansının hassas ölçümler yapmaya uygun olması, hem fiyatının ucuz olması hem de sağlamış olduğu titreşim verilerinin üç eksenli olması sebebi ile ADXL345 sensörü tercih edilmiştir. Titreşim için kullanılacak sensörün Arduino ile oldukça uyumlu çalışabiliyor olması nedeniyle veri toplama işlemleri bir Arduino Uno kullanılarak gerçekleştirilmiştir.

Titreşime bağlı diyagnostik çalışma, akustik çalışmaları desteklemek için yapıldığından ötürü titreşim verileri akustik veriler ile zaman olarak aynı miktarda kaydedilmiştir. Kaydedilen verilerin her biri 200 ms aralıklar ile üç eksenlerdeki değişimleri göstermektedir. Bu nedenle verilerin tek başlarına değil, topluca ortak özelliklerinin karşılaştırılması için yine özellik çıkarım tekniklerinden faydalanılmıştır. Bunun için istatistiksel özellik çıkarım teknikleri tercih edilmiş ve toplanan verilerdeki her bir eksen için ortalama değer, orta nokta, standart sapma, skewness ve kurtosis değerleri hesaplanmıştır. Dolayısıyla eğitilecek olan makine öğrenmesi modelinin giriş kısmını eksen başına beş, üç eksende ise toplam on beş veri oluşturmaktadır. Sonrasında ise bu verilere Z-score normalizasyonu uygulanarak, ortalama değeri 0 ve standart sapması ise 1 olan vektörler elde edilerek AI kısmına geçilmiştir.

AI metodu olarak sağlamış olduđu hız, basitlik ve aynı zamanda yüksek başarı potansiyeli ile FFNN metodu tercih edilmiştir. Önceki adımlarda özellik çıkarımları yapılmış olan titreşim verileri kullanılarak oluşturulmuş olan FFNN eğitilmiş ve performans değerlendirmeleri yapılmıştır. Bunun sonucunda titreşim verilerine bağlı akustik diyagnostik uygulamanın %97.20 doğruluk ile çalıştığı belirlenmiştir. Sonrasında ise tez çalışmasının ana konusunu oluşturan akıllı algılama çalışmasının son adımı olan topluluk öğrenmesi kısmına geçilmiştir.

Tez çalışmasının son adımında, AI modellerinin doğruluklarının arttırılması için topluluk öğrenmesi metodu benimsenmiş ve birden fazla modelin sınıflandıma sonuçlarının üçüncü bir makine öğrenmesi metodu ile iyileştirilmesinin araştırılması hedeflenmiştir. Bunun için hem akustik hem titreşim verilerinin birlikte değerlendirileceği bir yapı düşünülmüş ve önceki çalışmalardan farklı olarak akustik veriler MFCC özellik çıkarımı sonrasında Random Forest ile eğitilmeden önce Z-Score normalizasyona sokulmuştur. Ayrıca farklı modellerden gelecek sonuçlara bağlı olarak topluluk öğrenmesi yapılabilmesi için homojen veri miktarına ihtiyaç duyulduğundan ötürü titreşim dosyalarının ses dosyaları ile aynı miktarda olması amaçlanarak rastgele seçim yaptırılmıştır. Bunun sonucunda 60 hasarlı ve 60 hasarsız pervaneye ait veriler diğer tüm basamaklar aynı kalmak koşulu ile FFNN algoritması kullanılarak eğitilmiştir. Akustik veriler ise daha önceki çalışmada olduğu gibi Random Forest algoritması kullanılarak eğitilmiş, sonrasında ise hem akustik hem titreşime ait tahmineler kullanılarak başka bir Random Forest algoritması ile eğitilerek bir AI modeli oluşturulmuştur.

Çalışma performansına bakıldığında, rastgele veri seçimi nedeni ile FFNN ile eğitilen titreşim verilerinin doğruluk oranı %90'a düşmüş, Z-Score normalizasyon tekniği kullanılarak standardize edilen akustik veriler ile eğitilmiş Random Forest modelinin başarısı %99.96'dan %100'e çıkmış ve her iki modelin etiketlenmiş verileri ile eğitilen sonuncu Random Forest modelinin doğruluk sonucu ise %100 olarak elde edilmiştir.

İnsansız hava aracı mimarisinin SysML ve MBSE ile yaratılması, bu sistemler ile ilgili çalışmalar yapmakta olan araştırmacılara bir başlangıç noktası oluşturacaktır. Literatür içerisine bakıldığında, model tabanlı sistemler ile ilgili çalışmaların var olduğu ancak bu çalışmaların hiçbir tanesinde açık kaynak kodlu olarak yaratılmış bir insansız hava aracı mimarisi olmadığı gözükmemektedir. Tez çalışması içerisinde yapılan bu çalışma ile hem insansız hava araçlarının tüm sistemleri detaylı bir şekilde ortaya konmuş, hem

de bu sistemlerde kullanılabilecek ekipmanların gereksinimlerine de değinilerek araştırmacıların çalışmalarında referans alabilecekleri özellikler oluşturulmuştur.

Diyagnostik çalışmalardan elde edilen sonuçlar ise, insanlı hava araçlarının veya İHA'ların özellikle kritik sistemlerinde hata teşhisi amacı ile kullanılabilecek akustik ve titreşime bağlı diyagnostik yaklaşımlara oldukça etkili bir bakış açısı sunmaktadır.

Literatür içerisindeki çalışmalara bakıldığında, hasar tespiti, hata analizi ve diyagnostik konularında çalışmalar olduğu görülmektedir. Ancak söz konusu çalışmaların çoğu majör hasar durumları ve asimetric pervane profilleri ile yapılmış olduğu görülmektedir. Bu çalışmalar sonucunda araştırmacılar her ne kadar yüksek doğruluklar elde etmiş olsalar da, yüksek hasar durumları altında pervane hasarlarının belirlenmesi havacılık uygulamalarında AI teknolojilerinin kullanılması anlamında basit kalmaktadır. Tez çalışması içerisinde başarı ile tamamlanmış olan diyagnostik çalışma sonrasında, literatür içerisinde bulunan çalışmaların aksine minör ve simetrik hasar koşulları altında pervane hasarlarının farklı AI yöntemleri ile yüksek doğrulukla tanımlanması başarılmıştır. İlgili diyagnostik çalışmanın yapılması esnasında hava aracına harici bir ekipman takılmasına gerek kalmadan halihazırda mevcut IMU sensörünün kullanılarak bu çalışmaların geliştirilebileceği fikri de bu çalışmayı literatür içerisinde yer alan diğer çalışmalardan ayıran diğer bir noktadır.

Buna göre, ekipmanlar üzerinden elde edilen birbirinden farklı verilere dayalı olarak geliştirilecek bir topluluk öğrenmesi modeli ile çok fazla işlem gücü harcamadan oldukça etkili bir şekilde, doğruluk oranı yüksek ve AI destekli diyagnostik uygulama yapılabilir. Geliştirilmiş olan diyagnostik uygulama yeterli veri ile çok daha büyük sistemlerde başarılı sonuçlar ortaya koyabilir ve özellikle emniyeti tehlikeye atabilecek kritik sistemlerdeki bir hasarın belirlenmesinde kilit bir rol oynayabilir.

Hava araçları üzerinde AI tabanlı uygulamalar ile ilgili regülasyon ve sertifikasyon çalışmaları yeterince yaygınlaştıktan sonra, tez çalışması içerisinde geliştirilmiş olan method gerekli güvenilirlik seviyesini karşıladığı durumda kullanılabilir. Bu tip bir kullanımın güvenilirlik seviyesi, kalibrasyonların doğru ve hassas yapılması, sensörlerin hangi sistemlere nasıl yerleştirileceğinin belirlenmesi, algoritmaların farklı miktarda veriler ile eğitilmesi, performanslarının sürekli izlenmesi ve test ve validasyon süreçleri kullanılarak arttırılabilir. Belirli standart ve emniyet kriterlerini karşılaması sonrasında ise insanlı hava araçlarına entegrasyonu yapılabilir.

Ayrıca modele sağlanacak veri miktarına ve çeşidine bağlı olarak ileride yapılacak çalışmalarda bu sistemlerdeki hasarların ortaya çıkacağı zamanı kestirmede kullanılarak, prognostik uygulama olarak da henüz hasar yaşanmamış bir parçanın geleceği hakkında da önemli tahminlerde bulunabilir.



KAYNAKÇA

- [1] Peciak, M., & Skarka, W. (2022). Assessment of the potential of electric propulsion for general aviation using model-based system engineering (MBSE) methodology. *Aerospace*, 9(2), 74.
- [2] Mordecai, Y., Orhof, O., & Dori, D. (2016). Model-based interoperability engineering in systems-of-systems and civil aviation. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 48(4), 637-648.
- [3] Waseem, M., & Sadiq, M. U. (2018). Application of model-based systems engineering in small satellite conceptual design-A SysML approach. *IEEE Aerospace and Electronic Systems Magazine*, 33(4), 24-34.
- [4] Kaslow, D., Ayres, B., Cahill, P. T., Hart, L., & Yntema, R. (2017, March). A Model-Based Systems Engineering (MBSE) approach for defining the behaviors of CubeSats. In 2017 *IEEE Aerospace Conference* (pp. 1-14). IEEE.
- [5] Fei, X., Bin, C., Rui, L., & Shunhua, H. (2020, August). A model-based system engineering approach for aviation system design by applying SysML modeling. In 2020 *Chinese Control And Decision Conference (CCDC)* (pp. 1361-1366). IEEE.
- [6] Bajaj, M., Zwemer, D., Peak, R., Phung, A., Scott, A. G., & Wilson, M. (2011, March). Slim: collaborative model-based systems engineering workspace for next-generation complex systems. In 2011 *Aerospace Conference* (pp. 1-15). IEEE.
- [7] Estefan, J. A. (2007). Survey of model-based systems engineering (MBSE) methodologies. *IncoSE MBSE Focus Group*, 25(8), 1-12.
- [8] Ramos, A. L., Ferreira, J. V., & Barceló, J. (2011). Model-based systems engineering: An emerging approach for modern systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 42(1), 101-111.
- [9] Nielsen, C. B., Larsen, P. G., Fitzgerald, J., Woodcock, J., & Peleska, J. (2015). Systems of systems engineering: basic concepts, model-based techniques, and research directions. *ACM Computing Surveys (CSUR)*, 48(2), 1-41.
- [10] Steurer, M., Morozov, A., Janschek, K., & Neitzke, K. P. (2018). SysML-based profile for dependable UAV design. *IFAC-PapersOnLine*, 51(24), 1067-1074.

- [11] Massey, K., & Gaeta, R. (2010, June). Noise measurements of tactical UAVs. In *16th AIAA/CEAS aeroacoustics conference* (p. 3911).
- [12] Papa, U., Iannace, G., Del Core, G., & Giordano, G. (2017). Sound power level and sound pressure level characterization of a small unmanned aircraft system during flight operations. *Noise & Vibration Worldwide*, 48(5-6), 67-74.
- [13] Pechan, T., & Sescu, A. (2015). Experimental study of noise emitted by propeller's surface imperfections. *Applied Acoustics*, 92, 12-17.
- [14] Sinibaldi, G., & Marino, L. (2013). Experimental analysis on the noise of propellers for small UAV. *Applied Acoustics*, 74(1), 79-88.
- [15] Leslie, A., Wong, K. C., & Auld, D. (2008). Broadband noise reduction on a mini-UAV propeller. In *14th AIAA/CEAS Aeroacoustics Conference (29th AIAA Aeroacoustics Conference)* (p. 3069).
- [16] Miljković, D. (2018, May). Methods for attenuation of unmanned aerial vehicle noise. In *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)* (pp. 0914-0919). IEEE.
- [17] Ciaburro, G., Iannace, G., & Trematerra, A. (2020). Research for the presence of unmanned aerial vehicle inside closed environments with acoustic measurements. *Buildings*, 10(5), 96.
- [18] Al-Emadi, S., Al-Ali, A., Mohammad, A., & Al-Ali, A. (2019, June). Audio based drone detection and identification using deep learning. In *2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC)* (pp. 459-464). IEEE.
- [19] Altinors, A., Yol, F., & Yaman, O. (2021). A sound based method for fault detection with statistical feature extraction in UAV motors. *Applied Acoustics*, 183, 108325.
- [20] Glowacz, A. (2018). Acoustic based fault diagnosis of three-phase induction motor. *Applied Acoustics*, 137, 82-89.
- [21] Krishnasarma, A., Mostafavi Yazdi, S. J., Taylor, A., Ludwigsen, D., & Baqersad, J. (2021). Acoustic Signature Analysis and Sound Source Localization for a Three-Phase AC Induction Motor. *Energies*, 14(21), 7182.

- [22] Iannace, G., Ciaburro, G., & Trematerra, A. (2021). Acoustical unmanned aerial vehicle detection in indoor scenarios using logistic regression model. *Building Acoustics*, 28(1), 77-96.
- [23] Bondyra, A., Kołodziejczak, M., Kulikowski, R., & Giernacki, W. (2022). An acoustic fault detection and isolation system for multirotor UAV. *Energies*, 15(11), 3955.
- [24] Liu, W., Chen, Z., & Zheng, M. (2020). An audio-based fault diagnosis method for quadrotors using convolutional neural network and transfer learning. In 2020 *American Control Conference (ACC)* (pp. 1367-1372). IEEE.
- [25] de Jesus Rangel-Magdaleno, J., Ureña-Ureña, J., Hernández, A., & Perez-Rubio, C. (2018). Detection of unbalanced blade on UAV by means of audio signal. In 2018 *IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)* (pp. 1-5). IEEE.
- [26] Katta, S. S., Vuojärvi, K., Nandyala, S., Kovalainen, U. M., & Baddeley, L. (2022). Real-World On-Board Uav Audio Data Set For Propeller Anomalies. In *ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 146-150). IEEE.
- [27] Glowacz, A., Glowacz, W., Glowacz, Z., & Kozik, J. (2018). Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals. *Measurement*, 113, 1-9.
- [28] Radonjić, M., Vujnović, S., Krstić, A., & Zečević, Ž. (2022). IoT System for Detecting the Condition of Rotating Machines Based on Acoustic Signals. *Applied Sciences*, 12(9), 4385.
- [29] Kemalkar, A. K., & Bairagi, V. K. (2016, September). Engine fault diagnosis using sound analysis. In 2016 *International Conference on Automatic Control and Dynamic Optimization Techniques (ICACDOT)* (pp. 943-946). IEEE.
- [30] Iannace, G., Ciaburro, G., & Trematerra, A. (2019). Fault diagnosis for UAV blades using artificial neural network. *Robotics*, 8(3), 59.
- [31] Ji, S., Han, B., Zhang, Z., Wang, J., Lu, B., Yang, J., & Jiang, X. (2021). Parallel sparse filtering for intelligent fault diagnosis using acoustic signal processing. *Neurocomputing*, 462, 466-477.
- [32] Kołodziejczak, M., Puchalski, R., Bondyra, A., Sladic, S., & Giernacki, W. (2023). Toward lightweight acoustic fault detection and identification of UAV

rotors. In *2023 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 990-997). IEEE.

- [33] Gomez, M. S., Koschlik, A. K., Arts, E., & Raddatz, F. (2022). Non-destructive evaluation of the condition of a UAV's propellers by means of acoustics. In *NDE 4.0, Predictive Maintenance, and Communication and Energy Systems in a Globally Networked World* (Vol. 12049, pp. 22-30). SPIE.
- [34] Yang, P., Geng, H., Wen, C., & Liu, P. (2021). An intelligent quadrotor fault diagnosis method based on novel deep residual shrinkage network. *Drones*, 5(4), 133.
- [35] Pourpanah, F., Zhang, B., Ma, R., & Hao, Q. (2018). Anomaly detection and condition monitoring of UAV motors and propellers. In *2018 IEEE Sensors* (pp. 1-4). IEEE.
- [36] Benini, A., Ferracuti, F., Monteriù, A., & Radensleben, S. (2019, June). Fault detection of a VTOL UAV using acceleration measurements. In *2019 18th European Control Conference (ECC)* (pp. 3990-3995). IEEE.
- [37] Bondyra, A., Gasior, P., Gardecki, S., & Kasiński, A. (2017). Fault diagnosis and condition monitoring of UAV rotor using signal processing. In *2017 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)* (pp. 233-238). IEEE.
- [38] Yang, P., Wen, C., Geng, H., & Liu, P. (2021). Intelligent fault diagnosis method for blade damage of quad-rotor UAV based on stacked pruning sparse denoising autoencoder and convolutional neural network. *Machines*, 9(12), 360.
- [39] Ghalamchi, B., & Mueller, M. (2018). Vibration-based propeller fault diagnosis for multicopters. In *2018 International Conference on Unmanned Aircraft Systems (ICUAS)* (pp. 1041-1047). IEEE.
- [40] Al-Haddad, L. A., & Jaber, A. A. (2023). An intelligent fault diagnosis approach for multirotor UAVs based on deep neural network of multi-resolution transform features. *Drones*, 7(2), 82.
- [41] Palanisamy, R. P., Kulkarni, C. S., Corbetta, M., & Banerjee, P. (2022). Fault detection and Performance Monitoring of Propellers in Electric UAV. In *2022 IEEE Aerospace Conference (AERO)* (pp. 1-6). IEEE.
- [42] Tong, J. J., Zhang, W., Liao, F., Li, C. F., & Zhang, Y. F. (2023). Machine Learning for UAV Propeller Fault Detection based on a Hybrid Data Generation Model. arXiv preprint arXiv:2302.01556.

- [43] Ma, Y., Mustapha, F., Ishak, M. R., Abdul Rahim, S., & Mustapha, M. (2023). Structural fault diagnosis of UAV based on convolutional neural network and data processing technology. *Nondestructive Testing and Evaluation*, 1-20.
- [44] Zhang, W., Tong, J., Liao, F., & Zhang, Y. (2023). Difference-based Deep Convolutional Neural Network for Simulation-to-reality UAV Fault Diagnosis. arXiv preprint arXiv:2302.08117.
- [45] Cabahug, J., & Eslamiat, H. (2022). Failure Detection in Quadcopter UAVs Using K-Means Clustering. *Sensors*, 22(16), 6037.
- [46] Zhang, W., Tong, J., Liao, F., & Zhang, Y. (2023). Simulation-to-reality UAV Fault Diagnosis with Deep Learning. arXiv preprint arXiv:2302.04410.
- [47] Li, C., Sánchez, R. V., Zurita, G., Cerrada, M., & Cabrera, D. (2016). Fault diagnosis for rotating machinery using vibration measurement deep statistical feature learning. *Sensors*, 16(6), 895.
- [48] Baskaya, E., Bronz, M., & Delahaye, D. (2017, September). Fault detection & diagnosis for small UAVs via machine learning. In *2017 IEEE/AIAA 36th Digital Avionics Systems Conference (DASC)* (pp. 1-6). IEEE.
- [49] Guo, D., Zhong, M., Ji, H., Liu, Y., & Yang, R. (2018). A hybrid feature model and deep learning based fault diagnosis for unmanned aerial vehicle sensors. *Neurocomputing*, 319, 155-163.
- [50] Ghazali, M. H. M., & Rahiman, W. (2022). Vibration-based fault detection in drone using artificial intelligence. *IEEE Sensors Journal*, 22(9), 8439-8448.
- [51] Saied, M., Lussier, B., Fantoni, I., Francis, C., Shraim, H., & Sanahuja, G. (2015). Fault diagnosis and fault-tolerant control strategy for rotor failure in an octorotor. In *2015 IEEE international conference on robotics and automation (ICRA)* (pp. 5266-5271). IEEE.
- [52] Semke, W. H., & Dunlevy, M. D. (2019). A review of the vibration environment onboard small unmanned aircraft. In *Sensors and Instrumentation, Aircraft/Aerospace and Energy Harvesting, Volume 8: Proceedings of the 36th IMAC, A Conference and Exposition on Structural Dynamics 2018* (pp. 155-164). Springer International Publishing.
- [53] NT, S. K., Duba, P. K., Mannam, N. P. B., Mutnuri, V. S., & Rajalakshmi, P. (2024). Aeroacoustics and Vibration Analysis of Multirotor eVTOL for Sustainable Urban Air Mobility (UAM). *IEEE Sensors Letters*.

- [54] Radkowski, S., & Szulim, P. (2015). Analysis of vibration of rotors in unmanned aircraft. In J. Awrejcewicz et al. (Eds.), *Mechatronics: Ideas for Industrial Applications* (pp. 363-374). Springer International Publishing. https://doi.org/10.1007/978-3-319-10990-9_34
- [55] He, M., Fan, W., Yin, X., Li, L., Liu, N., Mo, W., & Han, H. (2021). Comparison of propellers and reduction of vibration in four-rotor unmanned aerial vehicle (UAV). In D. Zhen et al. (Eds.), *IncoME-V 2020, MMS 105* (pp. 514-522). Springer International Publishing. https://doi.org/10.1007/978-3-030-75793-9_48
- [56] Mizui, M., Yamamoto, I., & Ohsawa, R. (2012). Effects of propeller-balance on sensors in small-scale unmanned aerial vehicle. *IOSR Journal of Engineering*, 2(8), 23-27.
- [57] Simsiriwong, J., & Sullivan, R. W. (2012). Experimental vibration analysis of a composite UAV wing. *Mechanics of Advanced Materials and Structures*, 19(1-3), 196-206. <https://doi.org/10.1080/15376494.2011.572248>
- [58] Zhang, X., Zhao, Z., Wang, Z., & Wang, X. (2021). Fault detection and identification method for quadcopter based on airframe vibration signals. *Sensors*, 21(2), 581. <https://doi.org/10.3390/s21020581>
- [59] Ghazali, M. H. M., & Rahiman, W. (2023). Fuzzy-oriented anomaly inspection in unmanned aerial vehicle (UAV) based on MEMS accelerometers in multimode environment. *IEEE Transactions on Instrumentation and Measurement*, 72, 3530710. <https://doi.org/10.1109/TIM.2023.3315353>
- [60] Al-Haddad, L. A., & Jaber, A. A. (2023). Improved UAV blade unbalance prediction based on machine learning and ReliefF supreme feature ranking method. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 45, 463. <https://doi.org/10.1007/s40430-023-04386-5>
- [61] Al-Haddad, L. A., Jaber, A. A., Neranon, P., & Al-Haddad, S. A. (2023). Investigation of frequency-domain-based vibration signal analysis for UAV unbalance fault classification. *Engineering and Technology Journal*, 41(07), 915-923. <https://doi.org/10.30684/etj.2023.137412.1348>
- [62] Verbeke, J., & Debruyne, S. (2016). Vibration analysis of a UAV multirotor frame. In *Proceedings of ISMA 2016 - International Conference on Noise and Vibration Engineering* (pp. 101-110). KU Leuven, Faculty of Engineering Technology.
- [63] Gemayel, A., Manias, D. M., & Shami, A. (2024). Machine learning for pre/post flight UAV rotor defect detection using vibration analysis. In *Proceedings of the*

IEEE International Conference on Smart Cities (pp. 351-359). Western University, Department of Electrical and Computer Engineering.

- [64] Cocuzza, S., & Doria, A. (2021). Modeling and identification of vibrations in a UAV for aerial manipulation. In *Proceedings of the International Conference on Robotics and Automation* (pp. 251-260). University of Padova, Department of Industrial Engineering.
- [65] Al-Mashhadani, M. A. (2019). Random vibrations in unmanned aerial vehicles, mathematical analysis and control methodology based on expectation and probability. *Journal of Low Frequency Noise, Vibration and Active Control*, 38(1), 143-153. <https://doi.org/10.1177/1461348418813031>
- [66] Baldini, A., Felicetti, R., Ferracuti, F., Freddi, A., Iarlori, S., & Monteriù, A. (2023). Real-time propeller fault detection for multirotor drones based on vibration data analysis. *Engineering Applications of Artificial Intelligence*, 123, 106343. <https://doi.org/10.1016/j.engappai.2023.106343>
- [67] Liao, X., Jiang, T., Li, C., Yu, X., Peng, Z., & He, Q. (2024). Spatial-vibration-modulation-assisted blade damage localization for industrial quadrotor UAVs. *IEEE Transactions on Industrial Electronics*, 71(2), 2018-2026. <https://doi.org/10.1109/TIE.2023.3262883>
- [68] Ozkat, E. C. (2024). Vibration data-driven anomaly detection in UAVs: A deep learning approach. *Engineering Science and Technology, an International Journal*, 54, 101702. <https://doi.org/10.1016/j.jestch.2024.101702>
- [69] Jawad, S. M., & Jaber, A. A. (2023). Bearings health monitoring based on frequency-domain vibration signals analysis. *Engineering and Technology Journal*, 41(01), 86-95. <http://doi.org/10.30684/etj.2022.131581.1043>
- [70] Bondyra, A., Gąsior, P., Gardecki, S., & Kasiński, A. (2018). Development of the sensory network for the vibration-based fault detection and isolation in the multirotor UAV propulsion system. In *Proceedings of the 15th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2018)* (Vol. 2, pp. 102-109). SCITEPRESS. <https://doi.org/10.5220/0006846801020109>
- [71] Yoon, S., Kim, S., Bae, J., Kim, Y., & Kim, E. (2011). Experimental evaluation of fault diagnosis in a skew-configured UAV sensor system. *Control Engineering Practice*, 19(2), 158-173. <https://doi.org/10.1016/j.conengprac.2010.11.004>
- [72] Lee, J., Lee, W., Ko, S., & Oh, H. (2021). Fault classification and diagnosis of UAV motor based on estimated nonlinear parameter of steady-state model.

International Journal of Mechanical Engineering and Robotics Research, 10(1), 22-31. <https://doi.org/10.18178/ijmerr.10.1.22-31>

- [73] Saied, M., Lussier, B., Fantoni, I., Shraim, H., & Francis, C. (2017). Fault diagnosis and fault-tolerant control of an octorotor UAV using motors speeds measurements. *IFAC PapersOnLine*, 50(1), 5263-5268. <https://doi.org/10.1016/j.ifacol.2017.08.468>
- [74] Ghalamchi, B., Jia, Z., & Mueller, M. W. (2020). Real-time vibration-based propeller fault diagnosis for multicopters. *IEEE/ASME Transactions on Mechatronics*, 25(1), 395-406. <https://doi.org/10.1109/TMECH.2019.2947250>
- [75] Marichal, G. N., Tomás-Rodríguez, M., Hernández, Á., Castillo-Rivera, S., & Campoy, P. (2014). Vibration reduction for vision systems on board unmanned aerial vehicles using a neuro-fuzzy controller. *Journal of Vibration and Control*, 20(15), 2243-2253. <https://doi.org/10.1177/1077546313479632>
- [76] Ranjan, P., Devendra, M., Khan, S. A., & Goel, A. K. (2017). Vibration measurement on mini helicopter for electro-optic payload integration. *Proceedings of the 2017 International Conference on Nascent Technologies in the Engineering Field (ICNTE-2017)*, 1-6. <https://doi.org/10.1109/ICNTE.2017.7947978>
- [77] Bektash, O. M., & la Cour-Harbo, A. (2020). Vibration analysis for anomaly detection in unmanned aircraft. *Annual Conference of the Prognostics and Health Management Society* 2020, 12(1), 1-10. <https://doi.org/10.36001/phmconf.2020.v12i1.1143>
- [78] Puchalski, R., & Giernacki, W. (2022). UAV fault detection methods: State-of-the-art. *Drones*, 6(11), 330. <https://doi.org/10.3390/drones6110330>
- [79] Gorospe, G. E., & Kulkarni, C. S. (2017). A novel UAV electric propulsion testbed for diagnostics and prognostics. In *IEEE International Conference on Prognostics and Health Management (ICPHM)* (pp. 1-7). IEEE. <https://doi.org/10.1109/ICPHM.2017.7998310>
- [80] Tahir, M. M., Badshah, S., Hussain, A., & Khattak, M. A. (2018). Extracting accurate time domain features from vibration signals for reliable classification of bearing faults. *International Journal of Advanced and Applied Sciences*, 5(1), 156-163. <https://doi.org/10.21833/ijaas.2018.01.021>
- [81] Jiang, Y., Zhiyao, Z., Haoxiang, L., & Quan, Q. (2015). Fault detection and identification for quadrotor based on airframe vibration signals: A data-driven method. In *34th Chinese Control Conference (CCC)*, 6356-6361. <https://doi.org/10.1109/CCC.2015.7331064>

- [82] Chandra, D. S., & Rao, Y. S. (2019). Fault diagnosis of a double-row spherical roller bearing for induction motor using vibration monitoring technique. *Journal of Failure Analysis and Prevention*, 19(5), 1144-1152. <https://doi.org/10.1007/s11668-019-00712-z>

- [83] Stupar, S., Simonović, A., & Jovanović, M. (2012). Measurement and analysis of vibrations on the helicopter structure in order to detect defects of operating elements. *Scientific Technical Review*, 62(1), 58-63. <https://doi.org/10.5937/str1201058S>

- [84] Plasencia, G. N. M., Rodríguez, M. T., Rivera, S. C., & López, A. H. (2012). Modelling and analysis of vibrations in a UAV helicopter with a vision system. *International Journal of Advanced Robotic Systems*, 9, 220-228. <https://doi.org/10.5772/52761>

- [85] Jin, X., Zhao, M., Chow, T. W. S., & Pecht, M. (2013). Motor bearing fault diagnosis using trace ratio linear discriminant analysis. *IEEE Transactions on Industrial Electronics*. <https://doi.org/10.1109/TIE.2013.2273471>

- [86] Saucedo-Dorantes, J. J., Delgado-Prieto, M., Ortega-Redondo, J. A., Osornio-Rios, R. A., & Romero-Troncoso, R. J. (2016). Multiple-fault detection methodology based on vibration and current analysis applied to bearings in induction motors and gearboxes on the kinematic chain. *Shock and Vibration*, 2016, Article ID 5467643. <https://doi.org/10.1155/2016/5467643>

- [87] Henríquez, P., Alonso, J. B., Ferrer, M. A., & Travieso, C. M. (2014). Review of automatic fault diagnosis systems using audio and vibration signals. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 44(5), 642-652. <https://doi.org/10.1109/TSMCC.2013.2257752>

- [88] Dunbabin, M., Brosnan, S., Roberts, J., & Corke, P. (2004). Vibration isolation for autonomous helicopter flight. In *Proceedings of the 2004 IEEE International Conference on Robotics & Automation* (pp. 3609-3615). IEEE. <https://doi.org/10.1109/ROBOT.2004.1307248>

- [89] Nandi, S., Toliyat, H. A., & Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors—A review. *IEEE Transactions on Energy Conversion*, 20(4), 719-729. <https://doi.org/10.1109/TEC.2005.847955>

- [90] Van Der Maaten, L., Postma, E. O., & Van Den Herik, H. J. (2009). Dimensionality reduction: A comparative review. *Journal of Machine Learning Research*, 10(66-71), 13.

- [91] Khalid, S., Khalil, T., & Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. In *2014 science and information conference* (pp. 372-378). IEEE.
- [92] Krishna, G., Tran, C., Carnahan, M., Han, Y., & Tewfik, A. H. (2021, January). Generating EEG features from acoustic features. In *2020 28th European Signal Processing Conference (EUSIPCO)* (pp. 1100-1104). IEEE.
- [93] Sharma, A., Amarnath, M., & Kankar, P. K. (2016). Feature extraction and fault severity classification in ball bearings. *Journal of Vibration and Control*, 22(1), 176-192.
- [94] Cremona, C., Yang, S., & Dieleman, L. (2009). Overview of feature extraction techniques. In *Proceedings of the Third International Operational Modal Analysis Conference* (Vol. 2, pp. 381-390).
- [95] Liang, B., Iwnicki, S. D., & Zhao, Y. (2013). Application of power spectrum, cepstrum, higher order spectrum and neural network analyses for induction motor fault diagnosis. *Mechanical Systems and Signal Processing*, 39(1-2), 342-360.
- [96] Wang, G., Luo, Z., Qin, X., Leng, Y., & Wang, T. (2008). Fault identification and classification of rolling element bearing based on time-varying autoregressive spectrum. *Mechanical Systems and Signal Processing*, 22(4), 934-947.
- [97] Banerjee, T. P., & Das, S. (2012). Multi-sensor data fusion using support vector machine for motor fault detection. *Information Sciences*, 217, 96-107.
- [98] Bala, A., Kumar, A., & Birla, N. (2010). Voice command recognition system based on MFCC and DTW. *International Journal of Engineering Science and Technology*, 2(12), 7335-7342.
- [99] Frid, A., Ben-Shimol, Y., Manor, E., & Greenberg, S. (2024). Drones Detection Using a Fusion of RF and Acoustic Features and Deep Neural Networks. *Sensors*, 24(8), 2427.
- [100] Dumitrescu, C., Minea, M., Costea, I. M., Cosmin Chiva, I., & Semenescu, A. (2020). Development of an acoustic system for UAV detection. *Sensors*, 20(17), 4870.
- [101] Jiqing, L., Husheng, F., Qin, Y., & Chunhua, Z. (2021, June). Quad-rotor UAV Audio Recognition Based on Mel Spectrum with Binaural Representation and

CNN. In 2021 *International Conference on Computer Engineering and Application (ICCEA)* (pp. 285-290). IEEE.


[102] Dong, X., Yu, Z., Cao, W., Shi, Y., & Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14, 241-258.

[103] Zhou, Z. H. (2012). Ensemble methods: foundations and algorithms. *CRC press*.





EKLER


EK-1a




EK-1b







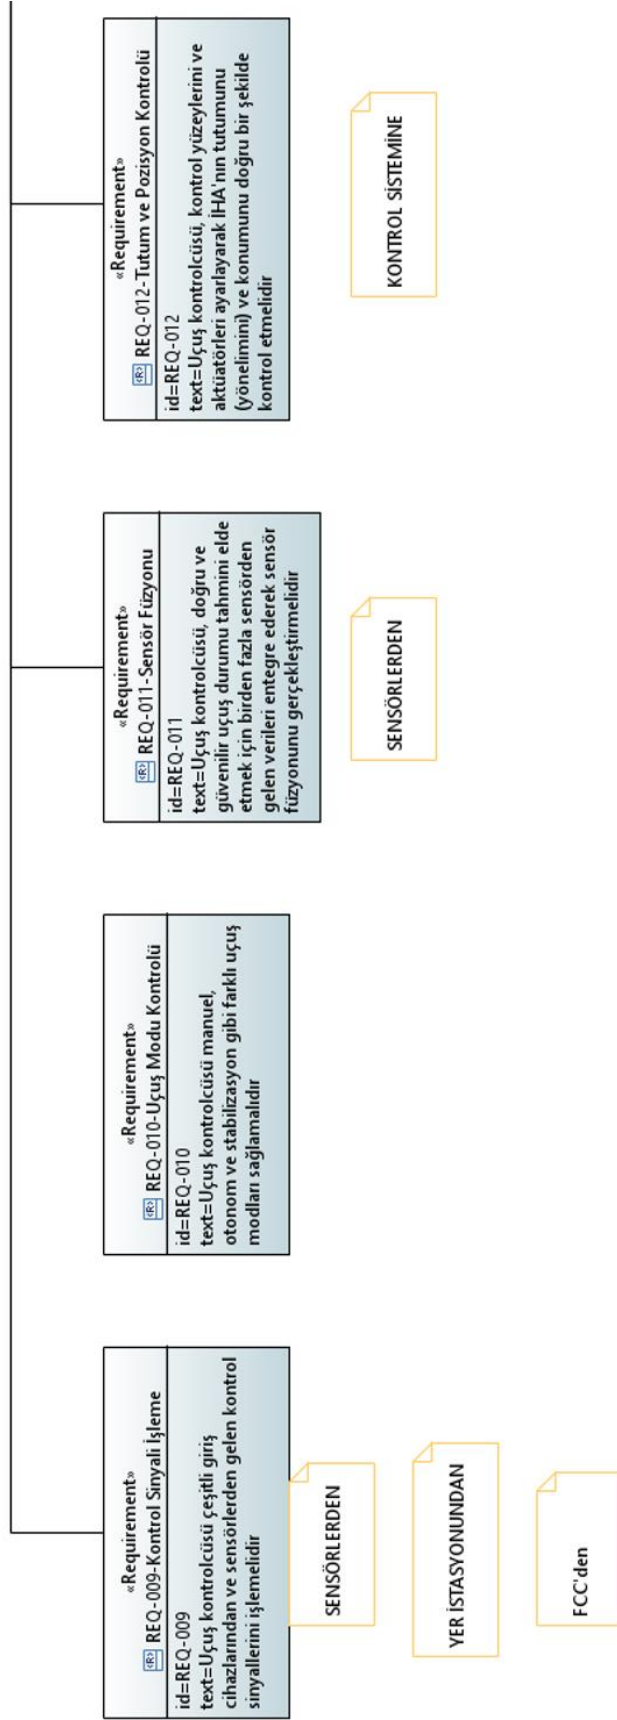


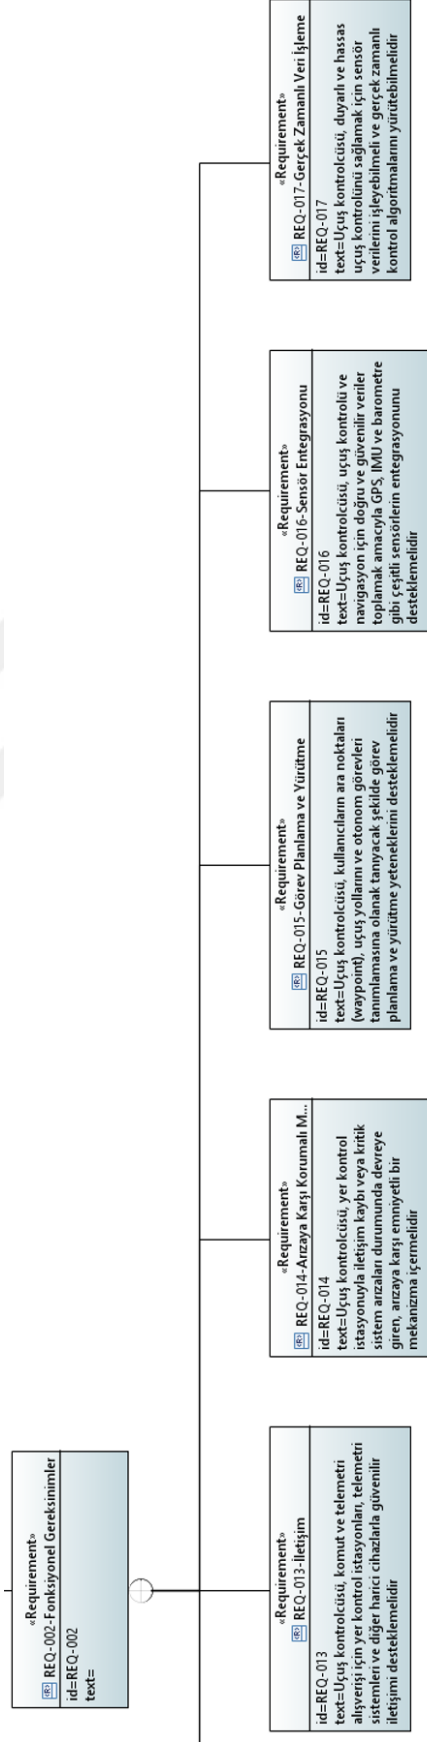


EK-1f












«Requirement» REQ-018-İşleme gücü	«Requirement» REQ-019-Yedeklilik	«Requirement» REQ-020-Güç Kaynağı	«Requirement» REQ-021-Yazılımın Güncellenebilirliği
id=REQ-018 text=Uçuş kontrolcüsü, kontrol ve navigasyon algoritmaları ile gerçek zamanlı hesaplamalar gerçekleştirmek için yeterli işlem gücüne sahip olmalıdır	id=REQ-019 text=Uçuş kontrolcüsü, ikili veya üçlü yedekli sistemler gibi yedeklilik mekanizmalarını içermelidir	id=REQ-20 text=Uçuş kontrolcüsü, belirtilen güç kaynağı voltaj aralığında çalışacak şekilde tasarlanmalı ve güç koruma mekanizmalarına sahip olmalıdır	id=REQ-021 text=Uçuş kontrolcüsü, gelecekteki gelişmeler, hata düzeltmeleri ve yeni özelliklerle uyumluluğu sağlamak için ürün yazılımının yükseltilebilirliğini desteklemelidir




EK-3a




EK-3b




EK-3c




EK-3d





EK-3e




EK-3f








EK-6a




EK-6b




EK-6c




EK-6d




EK-7a




EK-7b



EK-8a



EK-8b



EK-9

```
import librosa
import pandas as pd
import os

# Train and validation data folder definition
train_folder = "raw_sounds/Train/Damaged"
validation_folder = "raw_sounds/Validation/Damaged"

# Thrust levels and damage types definitions
thrust_levels = ["25-Thrust", "50-Thrust", "75-Thrust"]
damage_types = ["Dmg_Type-1", "Dmg_Type-2", "Dmg_Type-3", "Dmg_Type-4", "Dmg_Type-5"]

# Extracting MFCC features and save as CSV
def extract_and_save_mfcc(input_folder, output_csv):
    mfcc_data_list = []

    # Loop through thrust levels and damage types
    for thrust_level in thrust_levels:
        for damage_type in damage_types:
            folder_path = os.path.join(input_folder, thrust_level, damage_type)

            # Loop through audio files in the current folder
            for audio_file in os.listdir(folder_path):
                audio_path = os.path.join(folder_path, audio_file)

                # Load the audio clip
                y, sr = librosa.load(audio_path)

                # Extract MFCC features
                mfcc = librosa.feature.mfcc(y=y, sr=sr)
```

```
# Create a DataFrame with MFCC data
mfcc_df = pd.DataFrame(mfcc.T)

# Append the DataFrame to the list
mfcc_data_list.append(mfcc_df)

# Concatenate the list of MFCC DataFrames into one DataFrame
mfcc_data = pd.concat(mfcc_data_list, ignore_index=True)

# Save the MFCC data to a CSV file
mfcc_data.to_csv(output_csv, index=False)

# Extract function for both train and validation data
extract_and_save_mfcc(train_folder, "damaged_propellers_train_MFCC.csv")
extract_and_save_mfcc(validation_folder,
"damaged_propellers_validation_MFCC.csv")
```

EK-10

```
import librosa
import pandas as pd
import os

# Train and validation data folder definition
train_folder = "raw_sounds/Train/Undamaged"
validation_folder = "raw_sounds/Validation/Undamaged"

# Thrust levels and damage types definitions
thrust_levels = ["25-Thrust", "50-Thrust", "75-Thrust"]

# Extracting MFCC features and save as CSV
def extract_and_save_mfcc(input_folder, output_csv):
    mfcc_data_list = []

    # Loop through thrust levels
    for thrust_level in thrust_levels:
        folder_path = os.path.join(input_folder, thrust_level)

        # Loop through audio files in the current folder
        for audio_file in os.listdir(folder_path):
            audio_path = os.path.join(folder_path, audio_file)

            # Load the audio clip
            y, sr = librosa.load(audio_path)

            # Extract MFCC features
            mfcc = librosa.feature.mfcc(y=y, sr=sr)

            # Create a DataFrame with MFCC data
            mfcc_df = pd.DataFrame(mfcc.T)
```

```
# Append the DataFrame to the list
mfcc_data_list.append(mfcc_df)

# Concatenate the list of MFCC DataFrames into one DataFrame
mfcc_data = pd.concat(mfcc_data_list, ignore_index=True)

# Save the MFCC data to a CSV file
mfcc_data.to_csv(output_csv, index=False)

# Call the function for both train and validation data
extract_and_save_mfcc(train_folder, "undamaged_propellers_train_MFCC.csv")
extract_and_save_mfcc(validation_folder,
"undamaged_propellers_validation_MFCC.csv")
```

EK-11

```
import pandas as pd
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score
import joblib

# Load the data from CSV files
damaged_train = pd.read_csv("damaged_propellers_train_MFCC.csv")
damaged_validation = pd.read_csv("damaged_propellers_validation_MFCC.csv")
undamaged_train = pd.read_csv("undamaged_propellers_train_MFCC.csv")
undamaged_validation = pd.read_csv("undamaged_propellers_validation_MFCC.csv")

# Combine the training and validation datasets for both damaged and undamaged
propellers
X_train = pd.concat([damaged_train, undamaged_train], ignore_index=True)
y_train = pd.concat([pd.Series([1] * len(damaged_train)), pd.Series([0] *
len(undamaged_train))], ignore_index=True)

X_valid = pd.concat([damaged_validation, undamaged_validation],
ignore_index=True)
y_valid = pd.concat([pd.Series([1] * len(damaged_validation)), pd.Series([0] *
len(undamaged_validation))], ignore_index=True)

# Initialize and train a Random Forest classifier
model = RandomForestClassifier(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

# Predict on the validation set
y_pred = model.predict(X_valid)

# Evaluate the model
accuracy = accuracy_score(y_valid, y_pred)
```

```
print(f"Validation Accuracy: {accuracy}")
```

```
# Save the trained model
```

```
joblib.dump(model, 'propeller_damage_diagnosis_RF_model.pkl')
```



EK-12

```
import joblib
import librosa
import numpy as np

# Load the trained model
model = joblib.load('propeller_damage_diagnosis_RF_model.pkl')

# Path to sound file
audio_file_path = "25thrust-Rec-102.wav"

try:
    # Load the audio clip
    y, sr = librosa.load(audio_file_path)

    # MFCC feature extraction
    mfcc = librosa.feature.mfcc(y=y, sr=sr)

    # Calculation of the mean of each MFCC coefficient across frames
    mfcc_mean = np.mean(mfcc, axis=1)

    # Reshape the mean vector to for expected input shape (1, num_features)
    mfcc_mean_resaped = mfcc_mean.reshape(1, -1)

    # Making predictions using the model
    prediction = model.predict(mfcc_mean_resaped)

    # Interpret the prediction
    if prediction == 1:
        print("Propeller is damaged.")
    else:
        print("Propeller is not damaged.")
except Exception as e:
    print(str(e))
```

EK-13

```
import os
import numpy as np
import pandas as pd
import itertools
from scipy.stats import skew, kurtosis
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import confusion_matrix, classification_report,
accuracy_score

import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
from tensorflow.keras.utils import to_categorical
from sklearn.metrics import roc_curve, auc

def extract_features(data):
    features = []
    for i in range(data.shape[1]): # Iterate over each axis (column)
        features.extend([
            np.mean(data[:, i]),
            np.median(data[:, i]),
            np.std(data[:, i]),
            skew(data[:, i]),
            kurtosis(data[:, i])
        ])
    return features

def load_data_from_folder(folder_path):
    features, labels = [], []
    for root, dirs, files in os.walk(folder_path):
        for file in files:
            if file.endswith(".csv") and not file in ['101.csv', '102.csv']:
```

```

        file_path = os.path.join(root, file)
        data = pd.read_csv(file_path, header=None).values
        feats = extract_features(data)
        features.append(feats)
        labels.append(1 if 'Damaged' in root else 0)
    return np.array(features), np.array(labels)

# Load and process the data
train_features, train_labels = load_data_from_folder('AI-Train')
val_features, val_labels = load_data_from_folder('AI-Validation')

# Scale the features
scaler = StandardScaler()
train_features = scaler.fit_transform(train_features)
val_features = scaler.transform(val_features)

# Convert labels to categorical
train_labels = to_categorical(train_labels)
val_labels = to_categorical(val_labels)

# Neural Network Model
model = Sequential([
    Dense(128, activation='relu', input_dim=train_features.shape[1]),
    Dropout(0.5),
    Dense(64, activation='relu'),
    Dropout(0.5),
    Dense(2, activation='softmax')
])
model.compile(optimizer='adam', loss='categorical_crossentropy',
metrics=['accuracy'])

# Train the model

```

```
model.fit(train_features, train_labels, epochs=50, batch_size=32,
validation_data=(val_features, val_labels))
```

```
# Predict and evaluate the model
predictions = model.predict(val_features)
predicted_classes = np.argmax(predictions, axis=1)
true_classes = np.argmax(val_labels, axis=1)
accuracy = accuracy_score(true_classes, predicted_classes)
print("Accuracy:", accuracy)
print("Classification Report:\n", classification_report(true_classes,
predicted_classes))
```

```
# ROC Curve
probs = predictions[:, 1]
fpr, tpr, _ = roc_curve(true_classes, probs)
roc_auc = auc(fpr, tpr)
plt.figure()
plt.plot(fpr, tpr, label='ROC curve (area = %0.2f)' % roc_auc)
plt.plot([0, 1], [0, 1], 'k--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()
```

```
# Confusion Matrix
cm = confusion_matrix(true_classes, predicted_classes)
plt.figure(figsize=(8, 6))
plt.imshow(cm, interpolation='nearest', cmap=plt.cm.Blues)
plt.title('Confusion Matrix')
plt.colorbar()
```

```
tick_marks = np.arange(2)
classes = ['Undamaged', 'Damaged']
plt.xticks(tick_marks, classes, rotation=45)
plt.yticks(tick_marks, classes)
plt.xlabel('Predicted label')
plt.ylabel('True label')
plt.tight_layout()
for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
    plt.text(j, i, cm[i, j], horizontalalignment="center", color="white" if cm[i, j] >
cm.max() / 2 else "black")

plt.show()

# Save the model
model.save('damage_detection_nn_model.h5')
print("Model saved successfully.")
```

EK-14

```
import os
import numpy as np
import pandas as pd
from scipy.stats import skew, kurtosis
from sklearn.preprocessing import StandardScaler
from tensorflow.keras.models import load_model

def extract_features(data):
    features = []
    for i in range(data.shape[1]): # Iterate over each axis (column)
        features.extend([
            np.mean(data[:, i]),
            np.median(data[:, i]),
            np.std(data[:, i]),
            skew(data[:, i]),
            kurtosis(data[:, i])
        ])
    return features

def load_data_for_prediction(file_path):
    data = pd.read_csv(file_path, header=None).values
    features = extract_features(data)
    return np.array(features).reshape(1, -1)

# Load saved model
model = load_model('damage_detection_nn_model.h5')

# Load and preprocess new data for prediction
new_file_path = 'new_data.csv'
new_data_features = load_data_for_prediction(new_file_path)
```

```
# Scale the features using the same scaler used during training
scaler = StandardScaler()
train_features, _ = load_data_from_folder('AI-Train')
scaler.fit(train_features)
new_data_features = scaler.transform(new_data_features)

# Make predictions
predictions = model.predict(new_data_features)
predicted_class = np.argmax(predictions, axis=1)

# Interpret the prediction
if predicted_class == 0:
    print("The propeller is undamaged.")
else:
    print("The propeller is damaged.")
```

EK-15

```
import os
import numpy as np
import pandas as pd
import itertools
from sklearn.preprocessing import StandardScaler
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import classification_report, confusion_matrix,
accuracy_score, roc_curve, auc
import joblib
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, Input
from tensorflow.keras.utils import to_categorical
from scipy.stats import skew, kurtosis
from librosa.feature import mfcc
from librosa import load
import matplotlib.pyplot as plt

# extract statistical features from vibration data
def extract_features(data):
    return [
        np.mean(data), np.median(data), np.std(data),
        skew(data), kurtosis(data)
    ]

# load vibration data and extract features
def load_vibration_data(folder_path):
    features, labels = [], []
    for root, dirs, files in sorted(os.walk(folder_path)):
        for file in sorted(files):
            if file.endswith(".csv") and not file.startswith('101') and not
file.startswith('102'):
```

```

    path = os.path.join(root, file)
    data = pd.read_csv(path, header=None)
    feats = [extract_features(data[col]) for col in data.columns]
    features.append([item for sublist in feats for item in sublist])
    labels.append(1 if 'Damaged' in root else 0)
return np.array(features), np.array(labels)

```

```

# load acoustic data and extract MFCC features
def load_acoustic_data(folder_path, limit=None):
    features, labels = [], []
    for root, dirs, files in sorted(os.walk(folder_path)):
        for file in sorted(files):
            if file.endswith(".wav"):
                path = os.path.join(root, file)
                audio, sr = load(path, sr=None)
                mfcc_features = np.mean(mfcc(y=audio, sr=sr, n_mfcc=13), axis=1)
                features.append(mfcc_features)
                labels.append(1 if 'Damaged' in root else 0)
                if limit and len(labels) >= limit:
                    break
        if limit and len(labels) >= limit:
            break
    return np.array(features), np.array(labels)

```

```

# train vibration-based model using FFNN
def train_vibration_model(features, labels):
    scaler = StandardScaler()
    features_scaled = scaler.fit_transform(features)
    model = Sequential([
        Input(shape=(features_scaled.shape[1],)),
        Dense(128, activation='relu'),
        Dropout(0.5),
        Dense(64, activation='relu'),

```

```

        Dropout(0.5),
        Dense(2, activation='softmax')
    ])
    model.compile(optimizer='adam', loss='categorical_crossentropy',
metrics=['accuracy'])
    model.fit(features_scaled, to_categorical(labels), epochs=50, batch_size=32,
verbose=0)
    return model, scaler

```

Train acoustic-based model using RandomForest

```

def train_acoustic_model(features, labels):
    scaler = StandardScaler()
    features_scaled = scaler.fit_transform(features)
    model = RandomForestClassifier(n_estimators=100, random_state=42)
    model.fit(features_scaled, labels)
    return model, scaler

```

Train ensemble model using predictions from vibration and acoustic models

```

def train_ensemble_model(vib_preds, acou_preds, labels):
    combined_features = np.vstack((vib_preds, acou_preds)).T
    model = RandomForestClassifier(n_estimators=100, random_state=42)
    model.fit(combined_features, labels)
    return model

```

Evaluate the performance of a model

```

def evaluate_model(predictions, labels, features, model, model_name="Model"):
    accuracy = accuracy_score(labels, predictions)
    cm = confusion_matrix(labels, predictions)
    print(f"Accuracy of {model_name}: {accuracy}")
    print(f"Classification Report for {model_name}:\n", classification_report(labels,
predictions))
    plot_confusion_matrix(cm, ['Undamaged', 'Damaged'])

```

```

if isinstance(model, Sequential):
    probs = model.predict(features)[: , 1]
else:
    probs = model.predict_proba(features)[: , 1]

fpr, tpr, _ = roc_curve(labels, probs)
roc_auc = auc(fpr, tpr)
plot_roc_curve(fpr, tpr, roc_auc)

# Plot confusion matrix
def plot_confusion_matrix(cm, classes):
    plt.figure(figsize=(8, 6))
    plt.imshow(cm, interpolation='nearest', cmap=plt.cm.Blues)
    plt.title('Confusion Matrix')
    plt.colorbar()
    tick_marks = np.arange(len(classes))
    plt.xticks(tick_marks, classes, rotation=45)
    plt.yticks(tick_marks, classes)
    plt.tight_layout()
    plt.xlabel('Predicted label')
    plt.ylabel('True label')
    for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
        plt.text(j, i, format(cm[i, j], 'd'),
                 horizontalalignment="center",
                 color="white" if cm[i, j] > cm.max() / 2 else "black")
    plt.show()

# Plot ROC curve
def plot_roc_curve(fpr, tpr, roc_auc):
    plt.figure()
    plt.plot(fpr, tpr, color='darkorange', lw=2, label='ROC curve (area = %0.2f)' %
roc_auc)
    plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')

```

```
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()
```

```
# Load all data
```

```
train_vib_features, train_vib_labels = load_vibration_data('AI-Train')
train_acou_features, train_acou_labels = load_acoustic_data('Train-Acoustic')
val_vib_features, val_vib_labels = load_vibration_data('AI-Validation')
val_acou_features, val_acou_labels = load_acoustic_data('Validation-Acoustic')
```

```
# Separate damaged and undamaged samples in validation data
```

```
damaged_indices = np.where(val_vib_labels == 1)[0]
undamaged_indices = np.where(val_vib_labels == 0)[0]
```

```
# Sample 60 from each category
```

```
np.random.seed(42)
sampled_damaged_indices = np.random.choice(damaged_indices, size=60,
replace=False)
sampled_undamaged_indices = np.random.choice(undamaged_indices, size=60,
replace=False)
```

```
# Combine sampled indices
```

```
sample_indices = np.concatenate([sampled_damaged_indices,
sampled_undamaged_indices])
```

```
# Get sampled features and labels
```

```
val_vib_features_sampled = val_vib_features[sample_indices]
val_vib_labels_sampled = val_vib_labels[sample_indices]
```

```

# Train models
vib_model, vib_scaler = train_vibration_model(train_vib_features,
train_vib_labels)
acou_model, acou_scaler = train_acoustic_model(train_acou_features,
train_acou_labels)

# Save the models and scalers
joblib.dump(vib_model, 'vib_model.h5')
joblib.dump(acou_model, 'acou_model.pkl')
joblib.dump(vib_scaler, 'vib_scaler.pkl')
joblib.dump(acou_scaler, 'acou_scaler.pkl')

# Predict using models
vib_preds =
vib_model.predict(vib_scaler.transform(val_vib_features_sampled))[:, 1] # Select
probability of the damaged class
acou_preds =
acou_model.predict_proba(acou_scaler.transform(val_acou_features))[:, 1]

# Train and evaluate ensemble model
ensemble_model = train_ensemble_model(vib_preds, acou_preds,
val_vib_labels_sampled)
evaluate_model((vib_preds > 0.5).astype(int), val_vib_labels_sampled,
vib_scaler.transform(val_vib_features_sampled), vib_model, "Vibration FFNN Model")
evaluate_model((acou_preds > 0.5).astype(int), val_acou_labels,
acou_scaler.transform(val_acou_features), acou_model, "Acoustic RF Model")
ensemble_preds = ensemble_model.predict(np.vstack((vib_preds, acou_preds)).T)
evaluate_model(ensemble_preds, val_vib_labels_sampled, np.vstack((vib_preds,
acou_preds)).T, ensemble_model, "Ensemble RF Model")

# Save ensemble model
joblib.dump(ensemble_model, 'final_ensemble_model.pkl')
print("Final ensemble model saved successfully.")

```

```

import os
import numpy as np
import pandas as pd
import joblib

from tensorflow.keras.models import load_model
from sklearn.preprocessing import StandardScaler
from librosa.feature import mfcc
from librosa import load

# Load models and scalers
vib_model = load_model('vib_model.h5')
acou_model = joblib.load('acou_model.pkl')
vib_scaler = joblib.load('vib_scaler.pkl')
acou_scaler = joblib.load('acou_scaler.pkl')
ensemble_model = joblib.load('final_ensemble_model.pkl')

def extract_features(data):
    return [
        np.mean(data), np.median(data), np.std(data),
        skew(data), kurtosis(data)
    ]

def preprocess_vibration_data(csv_file_path):
    data = pd.read_csv(csv_file_path, header=None)
    feats = [extract_features(data[col]) for col in data.columns]
    features = np.array([item for sublist in feats for item in sublist])
    return features.reshape(1, -1) # Reshape for scaler

def preprocess_acoustic_data(wav_file_path):
    audio, sr = load(wav_file_path, sr=None)
    mfcc_features = np.mean(mfcc(y=audio, sr=sr, n_mfcc=13), axis=1)

```

```

return mfcc_features.reshape(1, -1) # Reshape for scaler

def make_prediction(vib_csv, acou_wav):
    # Preprocess vibration data
    vib_features = preprocess_vibration_data(vib_csv)
    vib_features_scaled = vib_scaler.transform(vib_features)

    # Preprocess acoustic data
    acou_features = preprocess_acoustic_data(acou_wav)
    acou_features_scaled = acou_scaler.transform(acou_features)

    # Predict using individual models
    vib_pred = vib_model.predict(vib_features_scaled)[: , 1] # Probability of
damaged class
    acou_pred = acou_model.predict_proba(acou_features_scaled)[: , 1]

    # Combine predictions and predict using ensemble model
    combined_features = np.vstack((vib_pred, acou_pred)).T
    final_pred = ensemble_model.predict(combined_features)

    return final_pred[0] # Return the final prediction

# Data path
vibration_csv_path = 'vibration_data.csv'
acoustic_wav_path = 'acoustic_data.wav'

prediction = make_prediction(vibration_csv_path, acoustic_wav_path)
print("Prediction:", "Damaged" if prediction == 1 else "Undamaged")

```

ÖZGEÇMİŞ

Adı Soyadı : Bahadır CİNOĞLU
Yabancı Dil : İngilizce
ORCID : 0000-0003-4518-0300

Eğitim ve Mesleki Geçmişi:

- 2022, Program Başkanı, Kapadokya Üniversitesi, İHA Teknolojisi ve Operatörlüğü
- 2022, Müdür, Kapadokya Üniversitesi, İHA Sistemleri Araştırma ve Uygulama Merkezi
- 2021, Öğretim Görevlisi, Kapadokya Üniversitesi
- 2013, Software Developer, Caunos B.V.
- 2019, Eskişehir Teknik Üniversitesi, Pilotaj Tezli YL
- 2015, Anadolu Üniversitesi, İşletme
- 2013, Beykent Üniversitesi, Bilgisayar Mühendisliği
- 2017, 50. Yıl Tahran Anadolu Lisesi

Projeler ve Yayınlar:

- Cinoğlu, B. (2024). Acoustic-Based Diagnostics for UAV Propeller Damage Using HNR and Gaussian Naive Bayes. Aircraft Engineering and Aerospace Technology, <https://doi.org/10.1108/AEAT-05-2024-0155>
- TEYDEB-1505, Proje No: 5210121, Otomatik Yükleme, Kurutma Sistemli, Tandem Tankli Ve Tasarruflu Uçak Janti Yıkama Makinesi Tasarımı, Prototip Üretimi Ve Testleri
- Cinoglu, Bahadır, Özge Küçükkör, Tahir Hikmet Karakoç, and Umut Durak. "Analyzing the Effects of Different MPPT Algorithms on Lithium-Ion Battery Degradation." In AIAA SCITECH 2023 Forum, p. 1592. 2023.
- TUBITAK 2531 Bilateral Cooperation Program with the German Academic Exchange Service (DAAD), 2021, German Aerospace Center (DLR) - Eskişehir Technical University (ESTU)

- Erasmus+, Youth Based Entrepreneurship Network of Unmanned Aerial Vehicle Industry and Technologies, 2020, Project Reference: 2020-3-TR01-KA205-097091

