



**UÇAK BAKIM SÜREÇLERİNDE SCADA İLE
KESTİRİMCİ BAKIM ANALİZİ**

Yüksek Lisans Tezi

Ufuk HİMMET

Eskişehir 2025

UÇAK BAKIM SÜREÇLERİNDE SCADA İLE KESTİRİMCİ BAKIM ANALİZİ

Ufuk HİMMET

YÜKSEK LİSANS TEZİ

Havacılık Elektrik ve Elektronik Anabilim Dalı

Danışman: Prof. Dr. Emre KIYAK

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ağustos 2025

JÜRİ VE ENSTİTÜ ONAYI

Ufuk HİMMET'in UÇAK BAKIM SÜREÇLERİNDE SCADA İLE KESTİRİMCİ BAKIM ANALİZİ başlıklı çalışması 06/08/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Havacılık Elektrik ve Elektronik Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Prof. Dr. Emre KIYAK

Üye

: Dr. Öğr. Üyesi Ayşe KAHVECİOĞLU

Üye

: Dr. Öğr. Üyesi Kadriye YAMAN

Prof. Dr. Harun BÖCÜK

Lisansüstü Eğitim Enstitüsü Müdürü

DANIřMAN ONAYI

Daniřmanlıđını yrttđm Yksek Lisans đrencisi Ufuk HİMMET, UAK BAKIM SRELERİNDE SCADA İLE KESTİRİMCİ BAKIM ANALİZİ bařlıklı tez alıřmasını tamamlamıřtır. Hazırlamıř olduđu tez tarafımca incelenmiř ve đrencinin tez savunma sınavına alınması bilimsel ve etik aıdan uygun grlmřtr.

Tez Daniřmanı

Prof. Dr. Emre KIYAK

ÖZET

UÇAK BAKIM SÜREÇLERİNDE SCADA İLE KESTİRİMCİ BAKIM ANALİZİ

Ufuk HİMMET

Havacılık Elektrik ve Elektronik Anabilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ağustos 2025

Danışman: Prof. Dr. Emre KIYAK

Bu çalışmada, uçak bakım süreçlerinde SCADA sistemleri ile kestirimci bakım yöntemlerinin entegrasyonu detaylı şekilde incelenmiştir. Havacılık sektöründe değişen koşullar ve uçuş güvenliği gereklilikleri, bakım faaliyetlerinin daha verimli şekilde yönetilmesini zorunlu kılmakta ve geleneksel bakım yaklaşımları yerine arıza oluşmadan önce tespit ve müdahale imkânı sunan kestirimci bakım yöntemleri ön plana çıkmaktadır.

Tez kapsamında öncelikle uçak bakım süreçlerine dair yapısal yaklaşımlar açıklanmış; sonra SCADA sistemlerinin yapısı ve havacılıktaki uygulama alanları incelenmiştir. Uçak sistemlerinden toplanan gerçek zamanlı verilerin SCADA ile yapay zekâ ve makine öğrenmesi algoritmaları kullanılarak analiz edildiği bir model önerilmiştir. Bu modelle bakım kararlarının otomatikleştirilebildiği, insan hatasının azaltılabildiği ve bakım maliyetlerinin optimize edilebildiği ortaya konmuştur.

Çalışmada ayrıca kestirimci bakım tekniklerinden çeşitli yöntemler detaylandırılmış; bu yöntemlerin SCADA sistemleriyle nasıl entegre edilebileceği açıklanmıştır. Yapay zekâ tabanlı karar destek sistemlerinin uçuşa elverişlilik süreçlerine katkısı teorik çerçevede modellenmiş, uluslararası otoritelerce belirlenen bakım regülasyonlarıyla uyumlu öneriler geliştirilmiştir.

Bu tez, havacılık bakım süreçlerinde kestirimci yaklaşımları bütüncül olarak ele alarak, bakım yönetimi adına akademik bir katkı sağlamayı hedeflemektedir.

Anahtar Sözcükler: SCADA, Kestirimci bakım, Uçak bakım

ABSTRACT

PREDICTIVE MAINTENANCE ANALYSIS WITH SCADA IN AIRCRAFT MAINTENANCE PROCESSES

Ufuk HİMMET

Department of Avionics

Eskişehir Technical University, Institute of Graduate Programs, August 2025

Supervisor: Prof. Dr. Emre KIYAK

In this study, the integration of SCADA systems with predictive maintenance methods in aircraft maintenance processes has been examined in detail. Changing conditions in the aviation sector and the requirements of flight safety necessitate more efficient management of maintenance activities, and predictive maintenance methods, which offer the opportunity for detection and intervention before a failure occurs, come to the forefront instead of traditional maintenance approaches.

Within the scope of the thesis, structural approaches to aircraft maintenance processes are first explained; then, the structure of SCADA systems and their application areas in aviation are examined. A model is proposed in which real-time data collected from aircraft systems is analyzed using SCADA systems along with artificial intelligence and machine learning algorithms. It has been demonstrated that with this model, maintenance decisions can be automated, human error can be reduced, and maintenance costs can be optimized.

The study also details various predictive maintenance techniques and explains how these methods can be integrated with SCADA systems. The contribution of artificial intelligence-based decision support systems to airworthiness processes is modeled within a theoretical framework, and recommendations aligned with maintenance regulations set by international authorities have been developed.

This thesis aims to provide an academic contribution to maintenance management by holistically addressing predictive approaches in aviation maintenance processes

Keywords: SCADA, Predictive maintenance, Aircraft maintenance.

TEŞEKKÜR

Bu tez çalışmasının hazırlanmasında katkı sağlayan tüm kişi ve kurumlara teşekkür ederim. Yüksek lisans eğitimim süresince bilgi ve tecrübeleriyle yol gösteren, akademik gelişimime büyük katkı sağlayan değerli danışmanım Prof. Dr. Emre Kıyak’a teşekkürü bir borç bilirim. Çalışma sürecinde anlayışları ve destekleriyle yanımda olan eşim Buse’ye, oğlum Ömer’e ve tüm aileme gönülden teşekkür ederim. Ayrıca, akademik yolculuğuma katkı sunan Eskişehir Doğal Gaz Dağıtım Şirketi’ndeki çalışma arkadaşım Fadime Kocatorun’a minnettarlığımı sunarım.

Tüm bu süreç, sadece bir akademik çalışma olmanın ötesinde, kişisel gelişimime ve vizyonuma katkı sunan değerli bir deneyim olmuştur.

Ufuk HİMMET

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 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.

Ufuk HİMMET

İÇİNDEKİLER

Sayfa

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.....	XIII
ŞEKİLLER DİZİNİ	XV
GÖRSELLER DİZİNİ	XVII
SİMGELER VE KISALTMALAR DİZİNİ	XVIII
1. GİRİŞ	1
2. UÇAK BAKIM SÜREÇLERİ	8
2.1. Uçak Bakımının Tanımı ve Önemi	8
2.2. Uçak Bakım Türleri	8
2.2.1. Planlı bakım	9
2.1.1.1. A tipi bakım (hat bakımı)	10
2.1.1.2. B tipi bakım	11
2.1.1.3. C tipi bakım (atölye bakımı).....	11
2.1.1.4. D tipi bakım (overhaul).....	12
2.2.2. Plansız bakım	12
2.2.3. Kestirimci bakım	13
2.3. Havacılıkta Bakım Standartları ve Regülasyonları.....	14
2.4. Uçak Bakım Süreçlerinde Güvenilirlik ve Güvenlik Faktörleri.....	16
3. KESTİRİMCİ BAKIM YÖNTEMLERİ VE TEKNİKLERİ	18

3.1. Kestirimci Bakımın Kavramsal Temelleri.....	18
3.2. Kestirimci Bakımın Havacılıkta Önemi.....	19
3.3. Kestirimci Bakım Yöntemleri	19
3.3.1. Titreşim analizi	19
3.3.1.1. Kullanım alanları.....	20
3.3.1.2. Tespit edebileceği yaygın arızalar.....	20
3.3.1.3. Ölçüm süreci	21
3.3.2. Yağ analizi	22
3.3.2.1. Kullanım alanları.....	22
3.3.2.2. Tespit edebileceği yaygın arızalar.....	22
3.3.2.3. Analiz yöntemleri	23
3.3.3. Termal görüntüleme analizi.....	23
3.3.3.1. Kullanım alanları.....	23
3.3.3.2. Tespit edebileceği yaygın arızalar.....	24
3.3.3.3. Kullanılan cihazlar ve yöntemler	24
3.3.4. Ultrasonik analiz.....	25
3.3.4.1. Kullanım alanları.....	25
3.3.4.2. Tespit edebileceği yaygın arızalar.....	25
3.3.4.3. Kullanılan cihazlar ve yöntemler:	26
3.3.5. Akustik emisyon analizi	26
3.3.5.1. Kullanım alanları.....	26
3.3.5.2. Tespit edebileceği yaygın arızalar.....	26
3.3.5.3. Kullanılan cihazlar ve yöntemler	27
3.4. SCADA Sistemleri ile Kestirimci Bakımın Entegrasyonu	27
3.5. Kestirimci Bakımda Kullanılan Veri Analizi ve Yorumlama Teknikleri.....	29
3.5.1. İstatistiksel analiz.....	29
3.5.1.1. Kullanım alanları.....	30
3.5.1.2. Tespit edebileceği arızalar	30
3.5.1.3. Analiz yöntemi ve ölçüm süreci.....	30
3.5.1.4. Avantajları.....	30
3.5.2. Spektral analiz	31
3.5.2.1. Kullanım alanları.....	31

3.5.2.2. <i>Tespit edebileceği arızalar</i>	31
3.5.2.3. <i>Analiz yöntemi ve ölçüm süreci</i>	31
3.5.2.4. <i>Avantajları</i>	32
3.5.3. Makine öğrenmesi	32
3.5.3.1. <i>Kullanım alanları</i>	32
3.5.3.2. <i>Tespit edebileceği arızalar</i>	32
3.5.3.3. <i>Analiz yöntemi ve ölçüm süreci</i>	33
3.5.3.4. <i>Avantajları</i>	33
3.5.4. Yapay zeka algoritmaları	33
3.5.4.1. <i>Kullanım alanları</i>	33
3.5.4.2. <i>Tespit edebileceği arızalar</i>	33
3.5.4.3. <i>Analiz yöntemi ve ölçüm süreci</i>	34
3.5.4.4. <i>Modelleme süreci</i>	34
3.5.4.5. <i>Avantajları</i>	34
3.5.4.6. <i>Yapay zekâ destekli kestirimci bakım</i>	35
3.6. Literatürde Kestirimci Bakım Uygulamaları	36
3.7. Kestirimci Bakımın Havacılıkta Uygulama Kısıtları	37
3.8. Gelecek Yönelimler	37
4. ÖNERİLEN SCADA YAKLAŞIMI	38
4.1. SCADA Sistemlerinin Tanımı	38
4.2. SCADA Sistemlerinin Tarihçesi ve Gelişimi	39
4.3. SCADA Sistemlerinin Yapısı ve Temel Bileşenleri	39
4.3.1. Veri toplama üniteleri (RTU ve PLC)	40
4.3.2. İletişim ağı ve protokolleri	41
4.3.3. Veri izleme ve kontrol merkezleri	45
4.3.4. SCADA işletim sistemi	47
4.3.4.1. <i>Sürücü ve etiket bağlantıları (Tag Editör)</i>	48
4.3.4.2. <i>Depolama</i>	48
4.3.4.3. <i>Raporlama</i>	48
4.3.4.4. <i>Alarm birimi</i>	49
4.3.4.5. <i>Trend birimi</i>	49
4.3.4.6. <i>Ekran tasarımı</i>	50

4.4. SCADA Sistemlerinin Havacılıkta Kullanım Alanları	51
4.4.1. Hava trafik kontrolü.....	51
4.4.2. Havaalanı operasyonları	52
4.4.3. Uçak bakımı	53
4.4.4. Uçak gövde ve yapı izleme	53
4.5. SCADA Sistemlerinin Havacılıkta Sağladığı Avantajlar	56
4.6. Havacılıkta SCADA Uygulamalarına Yönelik Zorluklar	56
4.7. Havacılıkta Dijitalleşme Süreci ve SCADA'nın Rolü	57
4.8. Gelecek Perspektifi ve Entegrasyon Potansiyeli.....	58
5. ANALİZ VE BULGULAR.....	59
5.1. Veri Seti Oluşturulması	59
5.1.1. Seçilen değişkenler	61
5.1.2. Değişkenlerin seçim gerekçesi ve literatür dayanakları.....	62
5.1.3. Arıza skoru hesaplaması	62
5.1.4. Arıza etiketi atama yöntemi.....	64
5.2. Yapay Zeka Algoritmaları ile Arıza Tahmini	65
5.2.1. Destek vektör makineleri (SVM) ile arıza tahmini.....	67
5.2.2. Karar ağacı (Decision) ile arıza tahmini.....	70
5.2.3. Yapay sinir ağı (ANN) ile arıza tahmini	73
5.2.4. Uzun kısa süreli bellek (LSTM) ile arıza tahmini.....	76
5.3. Yapay Zeka Algoritmalarının Karşılaştırılması	79
5.3.1. Doğruluk (Accuracy) karşılaştırması	79
5.3.2. Algoritmaların F1 skoru açısından karşılaştırılması	80
5.3.3. Algoritmaların karışıklık matrisi açısından karşılaştırılması.....	81
5.3.4. Algoritmaların ROC eğrisi ve AUC açısından karşılaştırılması.....	82
5.3.5. Genel değerlendirme ve yorum	83
5.4. Maliyet Analizi	85
5.5. SCADA Destekli Kestirimci Bakım Uygulaması.....	86
5.5.1. Veri toplama süreci.....	86
5.5.2. Veri ön işleme adımları	87
5.5.3. Algoritma kullanımı	87
5.5.4. Eşik değeri seçimi	87

5.5.5. Operatör müdahalesi ve bakım kaydı.....	88
6. SCADA İLE UÇAK BAKIM SÜREÇLERİNDE KESTİRİMCİ BAKIM ANALİZİ	89
6.1. SCADA-PdM Entegrasyonunun Genel Yapısı.....	89
6.2. SCADA-PdM Veri Akış Diyagramı.....	90
6.3. Kullanılan Yapay Zekâ Algoritmaları	90
6.4. Uygulama Senaryoları	91
6.5. Literatürdeki Uygulama Örnekleri.....	93
6.6. SCADA-PdM Entegrasyonunun Avantajları.....	93
6.7. Sınırlılıklar ve Geliştirme Alanları.....	94
6.8. SCADA Tabanlı Kestirimci Bakım Sisteminin Çalışma Prensipleri	94
6.9. SCADA Üzerinden Veri Toplama ve İzleme Yöntemleri.....	94
6.10. Toplanan Verilerin Analizi ve Arıza Tahminleme Algoritmaları	95
6.11. SCADA Sistemleri ile Uçak Sistemleri Entegrasyonu	95
6.12. SCADA Kullanılarak Yapılan Kestirimci Bakım Uygulamalarına Örnekler	95
7. SONUÇLAR VE ÖNERİLER.....	96
7.1. SCADA ile Kestirimci Bakımın Avantajları ve Sağladığı Katkılar	96
7.2. SCADA ile Kestirimci Bakımın Sınırlılıkları	96
7.3. Gelecekte SCADA-Kestirimci Bakım Sistemlerinin Evrimi	97
7.4. Literatür Perspektifi.....	98
7.5. SCADA Sistemlerinin Güvenlik Boyutu ve Regülasyonlar.....	98
7.6. Genel Değerlendirme	99
7.7. Araştırmadan Elde Edilen Genel Sonuçlar	100
7.8. Öneriler ve Gelecekte Yapılabilecek Çalışmalar	100
KAYNAKÇA.....	102
ÖZGEÇMİŞ	

TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Planlı uçak bakım türleri (Kinnison ve Siddiqui, 2013; FAA, 2021)	10
Tablo 2.2. ICAO, FAA ve EASA Karşılaştırma Tablosu	16
Tablo 3.1. Titreşim analizinin tespit edebileceği yaygın arıza türleri (Randall, 2011)	21
Tablo 3.2. Yağ analizinin tespit edebileceği yaygın arıza türleri (Wang ve Zhang, 2005)	22
Tablo 3.3. Termal görüntüleme analizinin tespit edebileceği yaygın arıza türleri (Usamentiaga ve diğerleri, 2014).....	24
Tablo 3.4. Ultrasonik analizinin tespit edebileceği yaygın arıza türleri	25
Tablo 3.5. Akustik emisyon analizinin tespit edebileceği yaygın arıza türleri (Grosse ve diğerleri, 2021)	27
Tablo 3.6. İstatistiksel analizinin tespit edebileceği yaygın arıza türleri (Mobley, 2002)	30
Tablo 3.7. Spektral analizinin tespit edebileceği yaygın arıza türleri (Randall, 2011)	31
Tablo 3.8. Makine öğrenmesinin tespit edebileceği yaygın arıza türleri (Susto ve diğerleri, 2014; Arena ve diğerleri, 2024)	32
Tablo 3.9. Yapay zeka algoritmalarının tespit edebileceği yaygın arıza türleri (Carvalho ve diğerleri, 2018).....	34
Tablo 5.1. Değişkenlerin aralığı, gerekçesi ve literatör dayanakları.....	62
Tablo 5.2. SVM analizi test verisindeki başarımlar sonucunda	67
Tablo 5.3. Karar Ağacı analizi test verisindeki başarımlar sonucunda	71
Tablo 5.4. Yapay sinir ağı analizi test verisindeki başarımlar sonucunda	73
Tablo 5.5. Uzun kısa süreli bellek analizi test verisindeki başarımlar sonucunda.....	76
Tablo 5.6. Algoritmaların doğruluk karşılaştırması	79
Tablo 5.7. Algoritmaların F1 skoru karşılaştırması	80
Tablo 5.8. Algoritmaların karışıklık matrisi karşılaştırması	81
Tablo 5.9. Algoritmaların ROC eğrisi ve AUC karşılaştırması	83

Tablo 5.10. Maliyet analizi için örnek senaryo.....	86
--	----



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Uçak bakım süreçleri (Kinnison ve Siddiqui (2013); Jardine ve diğerleri (2006); FAA (2021)).....	9
Şekil 2.2. Planlı bakım türleri (Kinnison ve Siddiqui (2013); FAA (2021); EASA (2020))	12
Şekil 4.1. Örnek SCADA veri toplama mimarisi	40
Şekil 4.2. Örnek RTU ve PLC görseli	41
Şekil 4.3. Örnek SCADA ile veri toplama cihazları arasındaki kablolu haberleşme altyapısı	42
Şekil 4.4. SCADA ile veri toplama cihazları arasındaki kablosuz haberleşme altyapısı	42
Şekil 4.5. Haberleşme protokolü ile iletişim	43
Şekil 4.6. SCADA işletim sisteminin birimleri	48
Şekil 4.7. Uçaklar için kullanılabilecek örnek SCADA mimarisi	54
Şekil 4.8. Uçak üzerinden okunan verilerin değişiminde SCADA sistemine gönderilen örnek veriler	54
Şekil 5.1. Sıcaklık değişimi zaman serisi	60
Şekil 5.2. Titreşim değişim zaman serisi	60
Şekil 5.3. Fan hızı değişimi zaman serisi	60
Şekil 5.4. Veri seti üretim ve hazırlık süreci akış diyagramı.....	61
Şekil 5.5. Oluşturulan arıza skorunun değişimi zaman serisi	63
Şekil 5.6. Oluşturulan 3000 kayıtlık verinin ilk 30 kaydı	65
Şekil 5.7. SVM analizi karışıklık matrisi	69
Şekil 5.8. SVM analizi ROC eğrisi.....	69
Şekil 5.9. Karar ağaçları analizi karışıklık matrisi	72
Şekil 5.10. Karar ağaçları analizi ROC eğrisi	72
Şekil 5.11. Yapay sinir ağı analizi karışıklık matrisi.....	74

Şekil 5.12. Yapay sinir ağı ROC eğrisi	75
Şekil 5.13. Uzun kısa süreli bellek analizi karışıklık matrisi	77
Şekil 5.14. Uzun kısa süreli bellek ROC eğrisi	77
Şekil 6.1. SCADA-PdM entegrasyonun genel yapısı.....	89
Şekil 6.2. SCADA-PdM veri akış diyagramı	90
Şekil 6.3. Örnek senaryo akış diyagramı	92



GÖRSELLER DİZİNİ

	<u>Sayfa</u>
Görsel 4.1. ESGAZ Merkez SCADA Odası	46
Görsel 4.2. ESGAZ SCADA ekranından örnek istasyon görseli.....	46
Görsel 4.3. atvise® SCADA yazılımına ait arayüz görseli.....	47
Görsel 4.4. ESGAZ SCADA web ara yüzü alarm ekranı	49
Görsel 4.5. SCADA trend ara yüz görseli.....	50
Görsel 4.6. Örnek SCADA trend ekranı (ESGAZ SCADA trend ekranından alınmıştır.).....	50
Görsel 4.7. Isparta Kara Havacılık Okulu havaalanı aydınlatma SCADA sistemi (CEDETAŞ).....	53
Görsel 4.8. Örnek kokpit SCADA ara yüzü (İşbilen ve Konar, 2020)	55

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zekâ)
ANN	: Artificial Neural Network (Yapay Sinir Ağı)
API	: Application Programming Interface (Uygulama Programlama Arayüzü)
CMS	: Condition Monitoring System (Durum İzleme Sistemi)
CMMS	: Computerized Maintenance Management System (Bilgisayarlı Bakım Yönetim Sistemi)
CNN	: Convolutional Neural Network (Evrimsel Sinir Ağı)
EASA	: European Union Aviation Safety Agency (Avrupa Havacılık Güvenliği Ajansı)
FAA	: Federal Aviation Administration (Federal Havacılık İdaresi)
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
HMI	: Human Machine Interface (İnsan-Makine Arayüzü)
ICAO	: International Civil Aviation Organization (Uluslararası Sivil Havacılık Örgütü)
IoT	: Internet of Things (Nesnelerin İnterneti)
IR	: Infrared (Kızılötesi)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
ML	: Machine Learning (Makine Öğrenmesi)
NTSB	: National Transportation Safety Board (Ulusal Ulaşım Güvenliği Kurulu)
OEE	: Overall Equipment Effectiveness (Genel Ekipman Etkinliği)
PdM	: Predictive Maintenance (Kestirimci Bakım)
PLC	: Programmable Logic Controller (Programlanabilir Mantıksal Denetleyici)
PT	: Pressure Transmitter (Basınç Ölçer)
RTU	: Remote Terminal Unit (Uzak Terminal Ünitesi)
SCADA	: Supervisory Control and Data Acquisition (Denetleyici Kontrol ve Veri Toplama)
TT	: Temperature Transmitter (Sıcaklık Ölçer)
URL	: Uniform Resource Locator (Tekdüzen Kaynak Bulucu)

1. GİRİŞ

Havacılık endüstrisi, küresel ulaşım ağının temel unsurlarından biri olarak hem teknolojik hem de operasyonel açıdan sürekli gelişim içindedir. Uçakların güvenli, verimli ve zamanında çalışabilmesi için bakım süreçlerinin sistematik, ileri teknoloji destekli biçimde yürütülmesi büyük önem taşımaktadır. Havacılık gibi yüksek güvenlik standartları gerektiren bir sektörde, bakım süreçlerinde yaşanabilecek gecikme veya hatalar; operasyonel kesintilere, yüksek maliyetlere ve hatta insan hayatını riske atabilecek ciddi güvenlik açıklarına neden olur.

Geleneksel bakım yaklaşımları genellikle zaman temelli veya arıza sonrası müdahale esasına dayalı olarak yürütülmektedir. Ancak bu yöntemler, teknolojik gelişmelerin hızına ayak uyduramamaktadır. Bu nedenle, bakım stratejilerinde önemli bir stratejik değişim yaşanmakta; arızaların oluşmadan önce tahmin edilmesini sağlayan 'kestirimci bakım' yaklaşımları ön plana çıkmaktadır. Kestirimci bakım, uçuşa elverişliliği artırmak, plansız bakım duruşlarını azaltmak ve bakım kaynaklarını etkin düzeyde kullanmak için yenilikçi çözümler sunmaktadır.

Kestirimci bakım uygulamalarının etkinliği büyük oranda veriye dayalı karar alma mekanizmalarıyla doğrudan ilişkilidir. Bu noktada, endüstriyel otomasyonun önemli bileşenlerinden biri olan SCADA (Supervisory Control and Data Acquisition – Denetleyici Kontrol ve Veri Toplama) sistemleri önemli bir rol üstlenmektedir. SCADA sistemleri, sahadan sensörler aracılığıyla gerçek zamanlı veri toplayarak bu verilerin izlenmesini ve analiz edilmesini mümkün kılmaktadır. Havacılık bakım süreçlerinde SCADA sistemlerinin kullanılması, teknik personelin karar alma süreçlerini güçlendirmekte ve kestirimci bakım algoritmalarının doğruluğunu artırmaktadır.

Bu tez çalışmasının temel amacı, uçak bakım süreçlerinde SCADA sistemlerinin kestirimci bakım yaklaşımlarıyla entegrasyonunu teorik olarak değerlendirmek ve bu teknolojik bütünleşmenin sektörel etkilerini ortaya koymaktır. Tez kapsamında, uçak bakım türleri, SCADA sistemlerinin yapısı, bileşenleri ve havacılıkta kullanım senaryoları detaylı olarak incelenecek; ayrıca kestirimci bakım tekniklerinin nasıl uygulanabileceği, hangi veri türlerinin kullanılacağı ve hangi analiz yöntemlerinin daha etkili olduğu konularına odaklanılacaktır.

Bu bağlamda, çalışmanın literatüre katkısı yalnızca teorik bilgilerle sınırlı kalmayacak; aynı zamanda havacılık sektöründe dijitalleşme, yapay zekâ entegrasyonu ve veri odaklı bakım yönetimi gibi güncel konularla uygulanabilirliği yüksek bir çözüm

önerisi sunacaktır. İlerleyen bölümlerde, SCADA ile kestirimci bakım arasındaki ilişki çok boyutlu olarak ele alınacak ve geleceğe dönük yenilikçi uygulamalara yönelik değerlendirmelere de yer verilecektir.

ICAO (2018) ve FAA (2021), modern uçak bakım süreçlerinde kestirimci bakım yaklaşımlarının temel gereklilik olduğunu vurgulamaktadır. EASA (2020) raporlarında, dijitalleşmenin havacılık bakımında dönüşüme yol açtığı ifade edilmiştir.

Son yıllarda havacılık sektöründe dijitalleşmenin hız kazanmasıyla birlikte, bakım yönetim sistemlerinde SCADA tabanlı çözümler ve kestirimci bakım stratejileri ön plana çıkmaktadır. Literatürde, bu entegrasyonun uçuş güvenliği, maliyet etkinliği ve sistem sürekliliği açısından önemli avantajlar sağladığı sıkça ifade edilmektedir.

Kestirimci bakım (predictive maintenance) kavramı, Endüstri 4.0 ile birlikte önem kazanarak, bakım faaliyetlerinin sadece geçmiş verilere değil, aynı zamanda gerçek zamanlı izleme ve yapay zeka temelli tahminlere dayandırılmasını sağlamıştır. Özellikle yüksek güvenilirlik ve maliyet optimizasyonunun kritik olduğu havacılık endüstrisinde, kestirimci bakım uygulamaları geleneksel bakım yaklaşımlarına göre daha verimli sonuçlar ortaya koymaktadır (Mobley, 2002; ICAO, 2018).

Kestirimci bakım uygulamaları, başlangıçta basit titreşim ve sıcaklık izlemelerine dayanırken, günümüzde gelişmiş makine öğrenmesi ve derin öğrenme algoritmaları sayesinde çok daha karmaşık sistemlere uygulanabilmektedir (Yang ve diğerleri, 2005; Widodo ve Yang, 2007). Özellikle destek vektör makineleri (SVM), yapay sinir ağları (ANN) ve uzun-kısa süreli bellek (LSTM) ağları bu alanda yaygın şekilde kullanılmaktadır (Ahmad ve diğerleri, 2014; Zhao ve diğerleri, 2017). Arena ve diğerleri (2024) tarafından geliştirilen çerçevede, algoritma seçiminin, sistemin doğasına ve veri yapısına göre dikkatle yapılması gerektiği vurgulanmaktadır.

Havacılık sektöründe bakım faaliyetleri, ICAO (2018) ve FAA (2021) tarafından yayımlanan regülasyonlarla detaylı şekilde tanımlanmıştır. Bu bağlamda, bakım faaliyetlerinin dijitalleştirilmesi, hem operasyonel güvenliğin artırılması hem de bakım maliyetlerinin azaltılması açısından önemli görülmektedir (Mofokeng ve diğerleri, 2020). SCADA sistemleri ile entegre edilmiş kestirimci bakım modelleri, uçak motoru, fren sistemleri ve hidrolik sistemler gibi alt bileşenlerin durumlarının sürekli izlenmesini sağlayarak, arızaların önceden tespiti için olanak tanımaktadır (Öztürk ve Demir, 2019).

Son yıllarda havacılık endüstrisinde dijital dönüşüm, bakım yönetim sistemlerinin daha entegre ve öngörülü olmasını zorunlu kılmıştır. Bu kapsamda, SCADA sistemleri

ile kestirimci bakım yaklaşımlarının entegrasyonu, sistemlerin sürekliliği ve etkinliği açısından önemli avantajlar sunmaktadır.

Boyer (2010), SCADA sistemlerinin endüstriyel otomasyon yapılarındaki kritik rolüne vurgu yaparak, veri toplama ve operatör kontrolünde sunduğu avantajları detaylandırmıştır. Clarke, Reynders ve Wright (2004) ise DNP3, IEC 60870-5 gibi protokollerin SCADA üzerindeki performans farklılıklarını analiz ederek bu protokollerin endüstriyel iletişimdeki önemine dikkat çekmiştir.

Colombo ve diğerleri (2014), SCADA sistemlerinin siber-fiziksel sistemlerle entegrasyonunun, endüstride esnekliği artırdığını ve bulut tabanlı çözümlerle ölçeklenebilirliğin mümkün olduğunu belirtmiştir. Benzer şekilde, Lee, Bagheri ve Kao (2015), Endüstri 4.0 temelli siber-fiziksel sistemlerin üretim süreçlerinde kestirimci bakıma katkısını teorik bir mimari üzerinden açıklamıştır.

Yapay zekâ tabanlı yaklaşımların SCADA sistemlerine entegre edilmesi yalnızca kestirimci bakım süreçlerinde değil, aynı zamanda sistem güvenliğinin artırılmasında da önemli rol oynamaktadır. Teixeira ve diğerleri (2018), bu kapsamda geliştirdikleri SCADA test ortamında, makine öğrenmesi algoritmalarıyla siber güvenlik tehditlerini başarıyla tespit edebilmiş ve bu teknolojinin SCADA sistemlerinde çok yönlü kullanım potansiyelini ortaya koymuştur.

Zonta ve diğerleri (2020), Endüstri 4.0 bağlamında kestirimci bakıma yönelik yapılan çalışmalarda, makine öğrenmesi tekniklerinin kullanımını sistematik olarak derlemiş ve bu yöntemlerin farklı endüstriyel ortamlarda başarıyla uygulandığını ortaya koymuştur. Widodo ve Yang (2007), destek vektör makineleri (SVM) kullanarak makine durum izleme ve arıza teşhisinde yüksek başarı oranlarının elde edildiğini belirtmiştir. Carvalho ve diğerleri (2019) ise yapay zekâ tabanlı kestirimci bakım yöntemlerinin sistematik bir incelemesini sunarak çeşitli makine öğrenmesi yaklaşımlarının avantajlarını değerlendirmiştir.

Bampoula ve diğerleri (2021), uzun kısa vadeli bellek (LSTM) ağlarının zaman serisi verilerde tahmin doğruluğunu artırdığını ve karmaşık örüntüleri başarıyla modellediğini göstermiştir. Yuan ve diğerleri (2016) ise, havacılık sistemlerinde LSTM tabanlı kestirimci modellerin geleneksel öğrenme algoritmalarına kıyasla daha başarılı tahmin performansı sunduğunu deneysel olarak ortaya koymuştur.

Yapay zekâ temelli kestirimci bakım uygulamaları, makine durum verilerinin analiziyle bakım süreçlerini optimize etmektedir. Lee ve diğerleri (2019), takım

tezgâhları sistemleri üzerinde gerçekleştirdikleri çalışmada, yapay zekâ tekniklerinin bakım kararlarının doğruluğunu artırdığını ve ekipman arızalarının önceden tespiti mümkün kıldığını ortaya koymuştur.

Derin öğrenme tekniklerinin, özellikle elektronik bileşen içeren karmaşık sistemlerde yüksek ayırt edici arıza özelliklerini başarılı şekilde öğrenebildiği literatürde belirtilmektedir. Liu ve diğerleri (2017), elektronik bileşenlerle zenginleştirilmiş analog sistemlerde geliştirdikleri derin öğrenme temelli yaklaşım ile arıza sınıflandırmasında yüksek doğruluk elde etmiş ve bu yöntemin kestirimci bakım uygulamaları için güçlü bir potansiyel sunduğunu vurgulamıştır.

Havacılık bakım süreçlerinde karşılaşılan operasyonel risklerin ampirik analizlerle değerlendirilmesi, bakım stratejilerinin geliştirilmesinde önemli katkılar sağlamaktadır. Marais ve Robichaud (2012), özellikle bakım sırasında oluşan sistematik riskleri inceleyerek bu süreçlerin istatistiksel yöntemlerle nasıl yönetilebileceğini ortaya koymuştur.

Titreşim analizi, özellikle rulman gibi döner parçalara sahip sistemlerde arıza belirtilerinin erken aşamada tespiti için etkin bir yöntemdir. Orhan (2002), rulmanlarla yataklanmış dinamik sistemlerde gerçekleştirdiği çalışmada, titreşim verileri kullanılarak arızaların tahmin edilmesini sağlamış ve bu yaklaşımın kestirimci bakım süreçlerinde uygulanabilirliğini ortaya koymuştur.

Endüstri 4.0 çerçevesinde makine öğrenmesi algoritmalarının kestirimci bakım uygulamalarına entegrasyonu, üretim sistemlerinin öngörülebilirliğini ve sürekliliğini artırmaktadır. Paolanti ve diğerleri (2018), gerçek zamanlı sensör verilerine dayalı bir makine öğrenmesi modeli geliştirerek, arıza olasılıklarını önceden tahmin etme konusunda başarılı sonuçlar elde etmiş ve bu yaklaşımın sanayi uygulamalarında etkinliğini ortaya koymuştur.

Derin öğrenme tabanlı modeller, özellikle karmaşık sistem davranışlarının öğrenilmesi ve arıza örüntülerinin otomatik olarak keşfedilmesi açısından kestirimci bakım uygulamalarında giderek daha fazla tercih edilmektedir. Serradilla ve diğerleri (2022), çeşitli derin öğrenme mimarilerini kapsamlı biçimde karşılaştırarak bu yaklaşımların başarı düzeylerini ve uygulama zorluklarını analiz etmiş; özellikle bakım kararlarının doğruluğunu artırma ve sistem kesintilerini azaltma açısından önemli potansiyel sunduğunu vurgulamıştır.

Durum izleme sistemleri, kestirimci bakım uygulamalarının temelini oluşturan veri tabanlı karar destek araçlarıdır. Surucu, Gadsden ve Yawney (2023), makine öğrenmesi temelli durum izleme yaklaşımlarını teorik çerçeveden uygulamaya kadar ele alarak, son gelişmelerin kestirimci bakım süreçlerine olan katkılarını kapsamlı biçimde incelemiştir.

EASA (2020) ve ICAO (2018) gibi uluslararası otoriteler, Part-145 kapsamında yetkilendirilmiş bakım kuruluşlarının dijital izleme sistemlerine entegre olmasını teşvik etmektedir. Bu sistemler sayesinde arıza tahmini ve önleyici bakım uygulamaları daha standart hale gelmektedir.

Havacılıkta bakım operasyonları, yüksek güvenlik standartları ve zamanlama kısıtları nedeniyle karmaşık bir yapıya sahiptir. Van den Bergh ve diğerleri (2013), uçak bakım süreçlerinin etkin bir şekilde yönetilmesi için optimizasyon tabanlı karar destek sistemlerinin kritik rol oynadığını vurgulamaktadır.

Wang ve diğerleri (2008), mühendislik sistemlerinde kalan kullanım ömrünün tahmini için benzerliğe dayalı bir kestirim yaklaşımı önermektedir. Bu yöntem, geçmiş arıza verileriyle mevcut sistem davranışını karşılaştırarak arıza zamanını öngörmeyi amaçlamaktadır. Bu yaklaşım, tezde geliştirilen yapay zeka modellerinin öğrenme temelleriyle örtüşmekte ve kestirimci bakım sistemlerinin doğruluk seviyesini artırmak adına kullanılabilir bir referans sunmaktadır.

White (1998), kestirimci bakım süreçlerinde sistem modelleme ve simülasyon tekniklerinin kullanılmasının, arıza oluşumunu önceden tahmin etme ve bakım planlamasını optimize etme açısından önemli katkılar sağladığını belirtmiştir. Bu yaklaşım, özellikle havacılık gibi karmaşık ve güvenlik-kritik sistemlerde kestirimci bakım uygulamalarının dijital ortamda test edilmesini mümkün kılmaktadır.

Arena ve diğerleri (2024), kestirimci bakım alanında makine öğrenmesi algoritmalarının seçimini yönlendiren bir çerçeve sunarak, algoritma seçiminde veri büyüklüğü, hedeflenen tahmin doğruluğu, modelin yorumlanabilirliği gibi kriterlerin değerlendirilmesini önermektedir.

Ye, Yong ve Han (2020), endüstriyel yapay zekânın temel teknolojilerini inceleyerek bu teknolojilerin kestirimci bakım uygulamalarındaki rolünü ortaya koymuşlardır. Çalışmada, veri analitiği, modelleme ve karar destek sistemlerinin entegrasyonu vurgulanarak, yapay zekâ tabanlı kestirimci bakımın üretim süreçlerindeki verimlilik ve güvenilirliği artırmadaki potansiyeline dikkat çekilmiştir.

Zeigler, Muzy ve Yılmaz (2012), yapay zekânın modelleme ve simülasyon süreçlerine entegrasyonunun, özellikle karmaşık sistemlerin davranışlarının öngörülmesinde önemli avantajlar sunduğunu belirtmiştir. Bu yaklaşım, kestirimci bakım sistemlerinde kullanılan algoritmaların performansını değerlendirmek ve sanal ortamda test etmek açısından değerli bir yöntem sunmaktadır.

Goldman, Fiedler ve King (2002), NTSB verilerine dayanan çalışmalarıyla, on yıllık süreçte genel havacılık kazalarının önemli bir kısmının doğrudan bakım kaynaklı olduğunu ortaya koymuştur. Bu bulgular, kestirimci bakım sistemlerinin yalnızca ekonomik değil, aynı zamanda güvenlik açısından da stratejik bir gereklilik olduğunu göstermektedir.

Lee ve diğerleri (2018), yapay zekâ tabanlı kestirimci sistemlerin havacılık bakım süreçlerinde operatör hatalarını minimize ettiğini ve karar süreçlerini daha güvenilir hale getirdiğini göstermiştir.

Davari ve diğerleri (2021), demiryolu sektöründe titreşim, sıcaklık ve akım gibi sensör verilerine dayalı olarak geliştirilen kestirimci bakım sistemlerini inceleyerek, yapay zeka algoritmalarının karar destek süreçlerine olan katkılarını kapsamlı biçimde ortaya koymuştur.

Endüstri 4.0 bağlamında kestirimci bakım, yalnızca makine öğrenmesi algoritmalarının uygulanmasıyla sınırlı kalmayıp, aynı zamanda açıklanabilirlik, veri güvenilirliği ve karar destek mekanizmalarıyla bütünleşik bir yapı gerektirmektedir. Dalzochio ve diğerleri (2020), bu bütünleşik yaklaşımın gerekliliğini vurgulayarak, kestirimci bakım sistemlerinin sürdürülebilir, esnek ve yorumlanabilir hale gelmesi için makine öğrenmesi ile nedensel akıl yürütmenin birlikte ele alınması gerektiğini ifade etmiştir.

Cardoso ve Ferreira (2020), yapay sinir ağları ve makine öğrenimi yöntemlerini kullanarak kestirimci bakım sistemlerinin uygulanabilirliğini analiz etmiş ve bu yaklaşımların bakım verimliliğini artırma potansiyelini vurgulamıştır.

Bampoula ve diğerleri (2021), siber-fiziksel üretim sistemlerinde LSTM-autoencoder mimarisi kullanarak kestirimci bakım yaklaşımı geliştirmiştir. Gerçek veri setleriyle yapılan uygulamada model, ekipmanın sağlık durumunu sınıflandırarak kalan faydalı ömrü tahmin etmiştir. Bu yöntem, SCADA benzeri sensör tabanlı veri altyapılarında gerçek zamanlı arıza tespiti ve bakım planlamasında kullanılabilir.

Aylak, Oral ve Yazıcı (2021) tarafından hazırlanan çalışma, lojistik sektöründe yapay zeka ve makine öğrenmesi yaklaşımının operasyonel verimliliği artırmadaki potansiyelini göstermektedir. Özellikle talep tahmini, rotalama optimizasyonu ve müşteri kaybının öngörülebilirliği bağlamında AI uygulamalarının iş süreçlerine etkileri analiz edilmiştir.

Sonuç olarak, mevcut literatür SCADA sistemlerinin kestirimci bakım stratejileri ile entegrasyonunun, operasyonel süreklilik, maliyet azaltımı ve erken uyarı mekanizmalarında önemli katkılar sağladığını ortaya koymaktadır. Bu tezde kullanılan modelleme ve analiz yöntemleri, literatürdeki bu çalışmalardan beslenerek özgün bir çerçeve sunmayı amaçlamaktadır.



2. UÇAK BAKIM SÜREÇLERİ

Uçak bakım süreçleri, havacılık endüstrisinde uçuş emniyeti ve operasyonel verimliliğin sağlanmasında kritik bir rol oynamaktadır. Uçakların kullanım ömrü boyunca karşılaşılabilecekleri teknik sorunların önlenmesi veya etkilerinin azaltılması, düzenli ve etkin bakım faaliyetlerinin gerçekleştirilmesiyle mümkündür. Bu bölümde uçak bakım süreçlerinin tanımı, bakım türleri, standartlar ve güvenlik faktörleri ayrıntılı olarak incelenmektedir.

2.1. Uçak Bakımının Tanımı ve Önemi

Uçak bakımı, hava araçlarının operasyonel ömrü boyunca güvenli, ekonomik ve etkin şekilde çalışmasını sağlamak amacıyla yürütülen planlı teknik uygulamalardır. Bakım süreçleri, uçuş güvenliğini en üst düzeyde tutmanın yanı sıra, uçak bileşenlerinin ömrünü uzatarak maliyetleri azaltmaya da yardımcı olur. Bu süreçlerin etkili yönetimi, uçakların görev sürekliliğini artırır ve havayolu işletmelerine rekabet avantajı sağlar.

Uçak bakım yönetimi, sadece teknik operasyonları değil, aynı zamanda lojistik, zamanlama ve insan kaynağı yönetimini de kapsayan çok yönlü bir süreçtir. Kinnison ve Siddiqui (2013), etkili bir bakım yönetiminin uçuş güvenliğini doğrudan etkilediğini vurgulamaktadır.

2.2. Uçak Bakım Türleri

Uçak bakım süreçleri genel olarak planlı bakım (scheduled maintenance), plansız bakım (unscheduled maintenance) ve kestirimci bakım (predictive maintenance) olmak üzere üç ana grupta sınıflandırılmaktadır.



Şekil 2.1. Uçak bakım süreçleri (Kinnison ve Siddiqui (2013); Jardine ve diğerleri (2006); FAA (2021))

2.2.1. Planlı bakım

Planlı bakım, önceden tanımlanmış zaman dilimleri veya belirli uçuş saati aralıklarına göre uygulanan periyodik bakım türüdür. Bu yöntem, zaman veya kullanıma dayalı bir proaktif bakım yaklaşımı olarak değerlendirilebilir. Planlı bakım faaliyetleri, uçak üreticilerinin ve havacılık otoritelerinin belirlediği standartlar doğrultusunda yapılmaktadır. Bu bakım türü, günlük kontrollerden (daily checks), A, B, C ve D seviyelerine kadar kapsamlı kontrollere uzanan farklı seviyelerde olabilir. Tablo 2.1’de planlı uçak bakım türleri görülmektedir. Bu bakım seviyelerinin detaylı açıklamaları aşağıda sunulmuştur.

Tablo 2.1. Planlı uçak bakım türleri (Kinnison ve Siddiqui, 2013; FAA, 2021)

Planlı Uçak Bakım Türleri Tablosu				
Bakım Türü	İngilizce Karşılığı	Sıklık	Süre	Kapsam ve Özellikler
A Tipi Bakım	Line Maintenance	400–600 uçuş saati	6–24 saat	Günlük kontroller, sıvı seviyesi, tekerlek ve fren kontrolleri
B Tipi Bakım	Intermediate Maintenance	6 ayda bir veya yılda bir	1–2 gün	Bazı sistem kontrolleri, kabin ekipmanları ve boya yüzey kontrolleri
C Tipi Bakım	Base Maintenance	18–24 ayda bir	1–2 hafta	Yapısal testler, sistem sök-tak işlemleri, kapsamlı aviyonik ve kabin kontrolleri
D Tipi Bakım	Heavy Maintenance / Overhaul	6–12 yılda bir	1–2 ay	Uçağın tamamının sökülüp incelenmesi, korozyon kontrolü, yapısal yenilemeler

2.1.1.1. A tipi bakım (hat bakımı)

Sıklık: Her 400–600 uçuş saati veya 200–300 uçuş döngüsü tamamlandığında uygulanır.

Süre: yaklaşık 6 ila 24 saat arasında sürer Bu bakım genellikle gece vardiyalarında ve operasyonel boşluklarda gerçekleştirilir.

Kapsam:

- Genel sistem kontrolü (hidrolik, pnömatik, yakıt, elektrik)
- Yağ ve sıvı seviyelerinin kontrolü ve dolumu
- Tekerlek, fren ve iniş takımı kontrolleri
- FOD (Foreign Object Damage) denetimi

Avantaj: Uçağın yerde bulunduğu süre içinde kısa sürede tamamlanabildiğinden operasyonel aksamalara yol açmaz.

2.1.1.2. B tipi bakım

Günümüzde birçok havayolu şirketi, B tipi bakımı A ve C bakımlarıyla birleştirerek entegre biçimde uygulamaktadır. Ancak bazı operatörler bu bakım türünü ayrı olarak sürdürmektedir.

Sıklık: Her 6 ayda bir ya da yılda bir kez uygulanmaktadır.

Süre: 1–2 gün

Kapsam:

- Uçak sistemlerinde belirli komponent değişimleri
- Dış yüzey boya, kaplama ve bağlantı noktalarının incelenmesi
- Kabin donanımlarının detaylı kontrolü

Avantaj: A tipi kontrolleri tamamlayıcıdır, derinlemesine kontrol sağlar.

2.1.1.3. C tipi bakım (atölye bakımı)

Sıklık: Genellikle her 18 ila 24 ayda bir uygulanır.

Süre: 1-2 hafta

Kapsam:

- Uçağın büyük sistemlerinin sökülüp incelenmesi
- Yapısal bütünlük kontrolleri (kanat, gövde, iniş takımı bağlantıları)
- Detaylı aviyonik sistem testleri
- Kabin içi sistemlerin bakım ve yenilenmesi

Avantaj: Geniş kapsamlı koruyucu bakım sağlar; uçağın hava elverişliliği güçlendirilir.

2.1.1.4. D tipi bakım (overhaul)

Sıklık: Genellikle 6 ila 12 yılda bir

Süre: 30–60 gün (operasyonel planlamaya bağlı olarak değişebilir)

Kapsam:

- Uçağın neredeyse tamamının sökülüp incelenmesi
- Yapısal revizyonlar ve büyük onarımlar
- Yeni komponent ve sistem entegrasyonları
- Korozyon kontrolü, boya soyulması ve yeniden kaplama

Avantaj: Uçağın ömrünü uzatan kapsamlı bir yenileme sürecidir.

Şekil 2.2’de planlı bakım türlerinin sıklığı ve bakım süresi sunulmuştur.



PLANLI BAKIM			
A TİPİ BAKIM (LINE MAINTENANCE)	B TİPİ BAKIM (INTERMEDIATE MAINTENANCE)	C TİPİ BAKIM (BASE MAINTENANCE)	D TİPİ BAKIM (HEAVY MAINTENANCE)
Sıklık: 400–600 uçuş saati	Sıklık: 6 ayda bir veya yılda bir	Sıklık: Yaklaşık 18–24 ayda bir	Sıklık: 6–12 yılda bir
Süre: 6–24 saat	Süre: 1–2 gün	Süre: 1–2 hafta	Süre: 30–60 gün

Şekil 2.2. Planlı bakım türleri (Kinnison ve Siddiqui (2013); FAA (2021); EASA (2020))

2.2.2. Plansız bakım

Plansız bakım, uçuş operasyonları veya rutin kontroller sırasında beklenmedik arıza ve teknik problemlerin ortaya çıkması halinde gerçekleştirilen bakım türüdür. Bu bakım türünün maliyetleri genellikle yüksektir çünkü uçuşlarda gecikmelere veya iptallere yol açabilir; bu nedenle mümkün olduğunca minimize edilmesi hedeflenmektedir. Plansız bakım, uçuş öncesi, uçuş esnası veya iniş sonrası ortaya çıkan teknik sorunların çözümüne yöneliktir ve genellikle reaktif bakım olarak tanımlanır.

Belirsiz Zamanlama: Arızaların ne zaman gerçekleşeceği önceden tahmin edilemez ve uçuş öncesi testlerde ya da uçuş sırasında ortaya çıkabilir.

Operasyonel Aksamalar: Uçuş iptali, gecikmeler veya alternatif uçak planlamalarına sebep olabilir.

Kritik Müdahale: Uçuş güvenliği açısından, müdahaleler çoğunlukla Minimum Ekipman Listesi (MEL) çerçevesinde değerlendirilir.

Yaygın Alanlar: Elektrik sistemleri, sensörler, iniş takımı ve kabin sistemleri gibi alanlarda sıkça görülür.

Kayıt Tutma: Yapılan tüm müdahaleler bakım kayıtlarına ve teknik logbook'a eksiksiz olarak işlenmelidir.

SCADA ve kestirimci bakım sistemlerinin olmaması, plansız bakım gereksinimlerini artırmaktadır.

2.2.3. Kestirimci bakım

Kestirimci bakım, gelişmiş veri analitiği ve makine öğrenmesi teknikleri kullanarak potansiyel arızaların önceden tahmin edilmesini sağlayan modern ve proaktif bir bakım stratejisidir. Bu yaklaşım, ekipman performansını sürekli izleyerek arızaların oluşmadan önce tespit edilmesine olanak verir ve böylece zamanında önleyici müdahaleler yapılabilir. Kestirimci bakımın temel faydası, operasyonel sürekliliğin artırılması ve beklenmedik arıza kaynaklı duruşların en aza indirilmesidir.

Kestirimci bakım sistemleri sensörler, SCADA sistemleri, uçak veri kayıt cihazları ve bakım yazılımları gibi kaynaklardan sürekli veri toplar. Bu veriler:

- Gerçek zamanlı olarak analiz edilir,
- Zaman serileri üzerinden eğilimler (trend analizleri) belirlenir,
- Yapay zekâ veya makine öğrenmesi algoritmalarıyla arıza olasılıkları hesaplanır.

Havacılıkta motor performansının izlenmesi, hidrolik basınçların takibi, fren sistemindeki sıcaklık değişimlerinin analizi, kabin iklim kontrol sistemleri arızalarının önceden belirlenmesi ve uçak gövdesi ile kanat yapılarında mikro çatlakların tespiti gibi alanlarda kestirimci bakım yöntemleri kullanılmaktadır.

Endüstri 4.0 kapsamında geliştirilen kestirimci bakım yaklaşımları, özellikle üretim hatlarında konveyör motorları gibi kritik bileşenlerin arızalarının önceden tahmin edilmesinde etkili sonuçlar vermektedir (Kiangala ve Wang, 2018).

Endüstri 4.0 kapsamında yapay zekâ tabanlı kestirimci bakım sistemlerinin gelişimi, son yıllarda bilimsel literatürde önemli bir artış göstermekte olup bu eğilim bibliyometrik analizlerle de ortaya konmuştur (Keleko ve diğerleri, 2022).

INCOSE (2024), sistem mühendisliği yaklaşımıyla kestirimci bakım stratejilerini birleştirerek, bakım verimliliğinin ve karar doğruluğunun artırılabilirliğini ortaya koymuştur.

2.3. Havacılıkta Bakım Standartları ve Regülasyonları

Havacılık sektöründe bakım faaliyetleri, uluslararası kuruluşlar tarafından belirlenen standartlara ve regülasyonlara uygun şekilde gerçekleştirilir. Uluslararası Sivil Havacılık Örgütü (ICAO), Federal Havacılık İdaresi (FAA) ve Avrupa Havacılık Güvenliği Ajansı (EASA) gibi kurumlar, uçak bakım süreçleri için detaylı kılavuzlar ve yönetmelikler yayımlamaktadır. Bu standartlar, uçuş güvenliğini artırmak ve operasyonel süreçleri uluslararası düzeyde birbiriyle uyumlu hale getirmek açısından büyük önem taşımaktadır. Organizasyonların bakım süreçleri konusundaki görev ve sorumluluklarına aşağıda değinilmiştir.

ICAO – International Civil Aviation Organization:

- Ulusal sivil havacılık otoriteleri için temel yasal çerçeveyi belirler.
- 19 adet Annex (Ek) dokümanla emniyet, bakım, uçuşa elverişlilik gibi alanları tanımlar.
- Bakım açısından özellikle Annex 6 (İşletme) ve Annex 8 (Uçuşa Elverişlilik) kritiktir.
- Doğrudan uygulama yetkisi yoktur; uyum ve denetimi ülkelere bırakır.

- SHGM (Sivil Havacılık Genel Müdürlüğü), FAA ve EASA gibi kuruluşlar ICAO'nun standartlarına göre kendi kurallarını şekillendirir.

Önemli Belgeler:

- Annex 6: Minimum ekipman listesi, bakım programı, sertifikasyon süreçleri
- Annex 8: Uçuşa elverişlilik, bakım dokümantasyonu, yedek parça uygunluğu
- Doc 9760: Airworthiness Manual – uygulama kılavuzu niteliğindedir.

FAA – Federal Aviation Administration:

- ABD hava sahası ve tescilli hava araçları için bağlayıcı düzenlemeleri yayımlar.
- Uçak bakım merkezleri, teknisyenler ve parçalar için sertifikasyon yapar.
- ABD tescilli tüm hava araçlarının uçuşa elverişlilik belgelerini düzenler.
- Part 43, Part 91, Part 145 gibi CFR (Code of Federal Regulations) kurallarına dayanır.
- FAA onaylı hava araçları, birçok ülkenin havacılık otoriteleri tarafından karşılıklı tanınır.

Önemli Yönetmelikler:

- 14 CFR Part 43: Bakım, önleyici bakım, yeniden imalat ve değişiklikler
- 14 CFR Part 145: Onaylı bakım kuruluşları için kural seti
- AC 43-204: Aircraft Maintenance Guidelines – rehber doküman niteliğindedir.

EASA – European Union Aviation Safety Agency:

- Avrupa'daki hava araçlarının bakım, üretim ve operasyonel süreçlerini düzenler.
- Ülke sivil havacılık otoriteleri ile birlikte çalışır. (örn. SHGM)
- ICAO standartlarını uygulayıcı ve detaylandırıcı mevzuata dönüştürür.
- Uçak bakım kuruluşları için Part-145, sürekli elverişlilik için Part-M gibi EASA Part'ları belirler.
- Tüm AB ülkeleri için ortak bir havacılık güvenliği yapısı oluşturur.

Önemli Yönetmelikler:

- EASA Part-145: Onaylı bakım organizasyonları için teknik ve yönetsel şartlar
- EASA Part-M: Sürekli uçuşa elverişlilik ve teknik kayıt yönetimi
- Part-66: Bakım teknisyenleri için lisanslama sistemi
- Part-21: Uçak ve parçaların üretimi ve sertifikasyonu

Tablo 2.2’de ICAO, FAA ve EASA örgütlerinin yaptırım gücü, temel görev, yönetmelik yapısı, sertifikasyon ve kapsama alanına göre karşılaştırmalarını görebilirsiniz.

Tablo 2.2. ICAO, FAA ve EASA Karşılaştırma Tablosu

ICAO, FAA, ve EASA Karşılaştırma Tablosu			
Özellik/Kurum	ICAO	FAA (ABD)	EASA (Avrupa)
Yaptırım Gücü	Tavsiye edici (uluslarüstü)	Yasal bağlayıcılık (ABD’de)	AB için bağlayıcı regülasyonlar
Temel Görev	Uluslararası standart belirleme	Ulusal uygulama ve denetim	Bölgesel uygulama + detaylandırma
Yönetmelik Yapısı	Annex (SARPs)	CFR (Code of Federal Regulations)	EASA Parts sistemi (145, M, 66 vs.)
Sertifikasyon	Hayır (ülkeler sorumlu)	Evet	Evet
Kapsama Alanı	193 ülke	ABD + FAA tanıyan ülkeler	AB ülkeleri + EASA anlaşmalı ülkeler

2.4. Uçak Bakım Süreçlerinde Güvenilirlik ve Güvenlik Faktörleri

Uçak bakım süreçlerinin etkinliği, güvenilirlik ve güvenlik faktörleri temelinde değerlendirilir. Güvenilirlik, uçak sistemlerinin belirli şartlar altında istenilen fonksiyonları kesintisiz biçimde yerine getirme kapasitesidir. Güvenlik ise uçuş

operasyonlarının emniyetli ve kazasız şekilde yürütölmesini ifade eder. Bakım süreçleri, bu iki faktörü maksimum düzeye çıkarmayı hedefler ve böylece uçuş emniyeti sağlanırken, operasyonel süreklilik ve maliyet etkinliği de artırılır.

Kestirimci bakım uygulamalarında yapay zekâ tabanlı çözümlerin başarısı, sadece algoritmik doğrulukla değil, aynı zamanda güvenilirlik, yorumlanabilirlik ve sürdürülebilirlik gibi faktörlerle de doğrudan ilişkilidir. Uçar ve diğerleri (2024), kestirimci bakım sistemlerinin tasarımında algoritmik güvenilirliğin ve etik denetimin önemine dikkat çekmiştir.



3. KESTİRİMCİ BAKIM YÖNTEMLERİ VE TEKNİKLERİ

Kestirimci bakım, endüstriyel sistemlerde ekipmanların arızalanmadan önce tespit edilmesini sağlayan veri odaklı bir bakım stratejisidir. Geleneksel bakım yaklaşımlarından farklı olarak kestirimci bakım, makine ve ekipmanlardan alınan gerçek zamanlı verilerin analiz edilmesi yoluyla arıza olasılıklarının önceden öngörülmesini ve bakım faaliyetlerinin bu öngörülere planlanmasını sağlar. Kestirimci bakım, havacılık, otomotiv, enerji ve üretim gibi birçok sektörde yaygın olarak kullanılmaktadır. Bu bölümde, havacılıkta yaygın olarak kullanılan temel kestirimci bakım yöntemleri ve teknikleri ele alınacaktır.

Havacılık sektörü, güvenilirliğin ve emniyetin en kritik olduğu endüstrilerden biridir. Uçuş emniyetinin sağlanması, operasyonel sürekliliğin artırılması ve bakım maliyetlerinin düşürülmesi, uçak bakım süreçlerinin temel hedefleri arasında yer alır. Geleneksel periyodik bakım faaliyetleri belli zaman aralıklarında ya da uçuş saati baz alınarak gerçekleştirilirken; kestirimci bakım stratejisi ile ekipmanların gerçek zamanlı durumuna göre bakım planlaması yapılmaktadır.

3.1. Kestirimci Bakımın Kavramsal Temelleri

Kestirimci bakım (Predictive Maintenance - PdM), bir sistemin veya ekipmanın gelecekte arızalanma olasılığını tahmin etmek amacıyla, gerçek zamanlı verilerin kullanıldığı bir bakım yaklaşımıdır. Geleneksel periyodik bakım sistemlerinden farklı olarak, PdM yalnızca ihtiyaç duyulduğunda müdahale edilmesini sağlar. Bu yaklaşım; sistem güvenilirliğini artırırken, gereksiz bakım maliyetlerini azaltmayı ve operasyonel sürekliliği sağlamayı hedefler.

Kestirimci bakım stratejisi, duruma dayalı bakım (Condition-Based Maintenance – CBM) yaklaşımının daha gelişmiş bir formu olarak kabul edilmektedir. CBM’de bakım kararı, ekipmanın mevcut durumu esas alınarak verilirken, PdM bu durumsal verilere ek olarak istatistiksel modelleme, makine öğrenmesi ve tahmine dayalı analiz teknikleri kullanılarak gelecekteki arıza eğilimlerini belirlemeyi amaçlar. Endüstri 4.0 kapsamında gelişen nesnelerin interneti (IoT), büyük veri analitiği, yapay zekâ algoritmaları ve bulut tabanlı sistemler, kestirimci bakım uygulamalarını daha etkin ve gerçek zamanlı hale getirmiştir. Bu teknolojiler sayesinde bakım kararları daha isabetli biçimde alınabilmekte ve insan hataları minimize edilmektedir.

3.2. Kestirimci Bakımın Havacılıkta Önemi

Havacılık sektörü, güvenlik açısından sıfır tolerans ilkesine dayalı olarak bakım süreçlerinin yüksek doğrulukta ve minimum riskle yönetilmesini gerektirir. Uçak bakım süreçlerinde yaşanabilecek herhangi bir gecikme, ciddi finansal kayıplara ve emniyet risklerine yol açabilir.

Kestirimci bakımın havacılıktaki önemi şu açılardan değerlendirilebilir:

- Uçuş emniyetinin artırılması: Olası arızaların önceden tespit edilmesiyle emniyet riskleri minimize edilir.
- Bakım maliyetlerinin azaltılması: Gereksiz parça değişimlerinin ve zaman kayıplarının önüne geçilir.
- Arıza öncesi erken uyarı sistemleri sayesinde insan hatalarının azaltılması: Otomatik arıza teşhis sistemleriyle hatalı kararların önüne geçilir.
- Uçakların yerde kalma süresinin (AOG – Aircraft on Ground) en aza indirilmesi: Arıza öncesi müdahale ile uçuş sürekliliği sağlanır.
- Bakım operasyonlarının daha planlı ve verimli yürütülmesi: Gerçek zamanlı verilerle optimize edilen bakım takvimi sayesinde kaynak kullanımı daha etkin hale gelir.

3.3. Kestirimci Bakım Yöntemleri

Havacılık sektöründe kestirimci bakım için çeşitli teknikler ve analiz yöntemleri kullanılmaktadır. Bu teknikler, uçak bileşenlerinin durumunu izlemek ve tahmine dayalı bakım süreçlerini optimize etmek için geliştirilmiştir. Bu tekniklerin bağımsız veya entegre şekilde kullanımı mümkündür.

3.3.1. Titreşim analizi

Titreşim analizi, dönen makinelerdeki mekanik problemleri erkenden tespit etmek amacıyla kullanılan, kestirimci bakımın en yaygın yöntemlerinden biridir. Uçak motorları, türbinler, fanlar, pompa sistemleri gibi rotatif (dönen) ekipmanlar, çalışma sırasında belirli frekans ve genlikte titreşim üretirler. Bu titreşimlerin ölçülmesi ve analiz edilmesiyle, sistemin sağlığı hakkında önemli bilgiler elde edilir.

Dengesiz çalışan bir makinenin titreşimleri, belirli bir frekans spektrumunda karakteristik bir imza oluşturur. Bu imzanın dışına çıkan değişiklikler, genellikle mekanik arızaların ön habercisidir.

Titreşim temelli arıza tespit yöntemlerinin kestirimci bakım uygulamalarındaki etkinliği birçok çalışmada gösterilmiştir. Örneğin Karadayı (2011), pompa sistemlerinde titreşim analizine dayalı olarak geliştirilen kestirimci bakım yaklaşımıyla erken arıza teşhisinin mümkün olduğunu ortaya koymuştur. Bu yaklaşım, uçak motoru bileşenlerinde de benzer şekilde uygulanabilirliği açısından önemlidir.

Yaman ve Karadayı (2014), pompa sistemlerinde arıza tespitine yönelik titreşim analizine dayalı bir kestirimci bakım yaklaşımı geliştirmiş ve bu yöntemin bakım planlamasında etkinliğini ortaya koymuştur.

Arslan (2010), fan sistemlerinde oluşturulan tipik arıza durumlarını titreşim verileri üzerinden analiz ederek, bu verilerin kestirimci bakım süreçlerinde arıza tespiti için etkili bir şekilde kullanılabileceğini ortaya koymuştur. Çalışma, mekanik sistemlerde titreşim temelli izleme yöntemlerinin erken uyarı amacıyla değerlendirilebileceğini göstermektedir.

3.3.1.1. Kullanım alanları

Titreşim analizin kullanım alanları aşağıda belirtilmiştir.

- **Uçak motorları (turbofan, turbojet):** Rotor, stator, kompresör, fan sistemlerinde
- **Hidrolik pompalar ve aktuatörler:** Yüksek devirli çalışan hassas parçaların izlenmesinde
- **Klimatizasyon sistemleri:** Fanlar ve kompresörlerin titreşim verilerinin takibinde
- **Yakıt ve yağ pompalama sistemleri:** Pompa dengesizlerinin izlenmesinde

3.3.1.2. Tespit edebileceği yaygın arızalar

Titreşim analizin tespit edebileceği yaygın arıza türleri Tablo 3.1’de belirtilmiştir.

Tablo 3.1. *Titreşim analizinin tespit edebileceği yaygın arıza türleri (Randall, 2011)*

Arıza Türü	Açıklama
Balanssızlık	Dönme eksenini etrafında ağırlık dağılımı dengesizliğidir. Genellikle $1\times$ RPM frekansında görülür.
Rulman Arızası	Rulman yüzeyinde aşınma veya çatlakla oluşur. Yüksek frekans bileşenleri oluşur.
Eksenel Kaçıklık	Bağlantılı parçaların eksenleri uyuşmadığında oluşur. $1\times$, $2\times$ harmonikler olabilir.
Gevşeklik	Cıvata gevşemesi veya yatak boşluğu gibi sorunlarda, düzensiz titreşim artışı görülür.
Kanat/Pal Hasarı	Fan veya kompresör kanatlarında eğilme, çatlak gibi sorunlar analizle tespit edilir.

3.3.1.3. Ölçüm süreci

- Sensörler motor, yatak ve gövde gibi kritik bileşenlere monte edilir.
- Zaman domeninde veri toplanır.
- Hızlı Fourier Dönüşümü (FFT) ile frekans domenine çevrilir.
- Trend analizi ile geçmiş veriler karşılaştırılarak anormallikler tespit edilir.
- Eşik değerlerinin aşılması durumunda sistem uyarı verir.

Titreşim analizinin yapay zeka entegrasyonu sayesinde , kestirimci bakım süreçleri daha da akıllı hale gelmiştir. Bu kapsamda;

Makine öğrenmesi (ML) algoritmalarıyla arıza sınıflandırması yapılabilir.

Zaman serisi tahminleri için LSTM (Long-Short-Term Memory) ve ARIMA gibi modeller kullanılabilir.

Anomali tespiti ile daha önce görülmemiş arızalar erken zamanda tespit edilebilir.

3.3.2. Yağ analizi

Yağ analizi, uçak motorları ve hidrolik sistemlerde kullanılan önemli bir kestirimci bakım yöntemidir. Bu yöntemde, sistemde dolaşan yağdan düzenli aralıklarla numune alınarak içerdiği metal partiküller, kimyasal bileşikler, oksidasyon seviyesi ve kirleticiler analiz edilir. Bu analiz sayesinde ekipmanın iç yüzeyinde meydana gelen aşınmalar ve potansiyel arızalar erken zamanda tespit edilebilir.

3.3.2.1. Kullanım alanları

Yağ analizinin kullanım alanları aşağıda belirtilmiştir.

- Turbofan ve turbojet motorları
- Hidrolik aktüatör sistemleri
- Yağlama sistemleri
- İniş takımı hidrolik devreleri
- Dişli kutuları ve transmisyon sistemleri

3.3.2.2. Tespit edebileceği yaygın arızalar

Yağ analizinin tespit edebileceği yaygın arıza türleri Tablo 3.2’de sunulmuştur.

Tablo 3.2. Yağ analizinin tespit edebileceği yaygın arıza türleri (Wang ve Zhang, 2005)

Parametre	Açıklama ve Arıza İpuçları
Metal Partikülleri (Fe, Al, Cr)	Yatak aşınması, rotor ve stator sürtünmeleri, rulman bozulması
Oksidasyon Ürünleri	Yağın yaşlanması veya aşırı sıcaklık nedeniyle bozunması
Viskozite	Düşük viskozite yağ seyrelmesi, yüksek viskozite kirlenme belirtisidir
Su ve Glikol	Sızdırmazlık kaybı, harici sıvı karışımı
Yanma Artıkları	Yakıt sisteminde sızıntı veya eksik yanma belirtisi

3.3.2.3. Analiz yöntemleri

Yağ analizi için başlıca yöntemler aşağıda sıralanmıştır.

- Spektrometrik analiz: Metal partikül ölçümü (Fe, Cu, Cr vb.)
- FTIR (Fourier Transform Infrared) analizi: Yağ içindeki kimyasal bileşiklerin belirlenmesi
- Viskozimetre: Yağ yoğunluğunun ölçümü
- Su içeriği testleri: Karl Fischer titrasyonu, dielektrik sabit ölçümü ile nem belirleme
- Parçacık sayımı: Optik ve lazerli sensörlerle partikül yoğunluğu ölçümü

Yapay zekâ destekli sistemler, geçmiş yağ analiz verilerinden öğrenerek anomali tespiti gerçekleştirebilir. Zaman serisi analizi ile belirli parametrelerdeki sapmaları tanımlayan modeller, bakım zamanlaması için uyarı eşikleri oluşturabilir. Bu sayede kestirimci bakımda operatöre karar destek sistemleri sağlanmış olur.

3.3.3. Termal görüntüleme analizi

Termal görüntüleme analizi, ekipmanların yüzey sıcaklıklarını temassız bir şekilde tespit etmek için kullanılan önemli bir kestirimci bakım yöntemidir. Uçaklarda özellikle elektriksel bileşenler, motorlar, fren sistemleri, hidrolik sistemler ve akışkan devreler gibi alanlarda uygulanır. Bu yöntem, yüzeydeki ısı farklılıklarını termal görüntüler veya kızılötesi görselleştirerek, arıza potansiyeli taşıyan bölgeleri erken aşamada tespit etmeyi sağlar.

3.3.3.1. Kullanım alanları

Termal görüntüleme analizinin havacılıkta başlıca kullanım alanları aşağıda sıralanmıştır:

- Elektrik sistemleri: Kablo bağlantıları, devre elemanları
- Fren sistemleri ve iniş takımı: Termal denge ve aşırı ısınma kontrolleri
- Uçak motor dış yüzeyleri: Sıcaklık izleme ve anomalilerin belirlenmesi
- Hidrolik sistem bağlantı noktaları: Sıvı kaçaqları veya sürtünme kaynaklı sıcaklık artışı

- Kompozit malzemeler: Yapısal stres ve sürtünmeye bağlı sıcaklık değişimlerinin izlenmesi

3.3.3.2. Tespit edebileceği yaygın arızalar

Termal görüntüleme analizinin tespit edebileceği yaygın arıza türleri Tablo 3.3’de sunulmuştur:

Tablo 3.3. Termal görüntüleme analizinin tespit edebileceği yaygın arıza türleri (Usamentiaga ve diğerleri, 2014)

Arıza Türü	Açıklama
Aşırı Isınma	Elektrik bağlantılarında gevşeme veya fazla akım nedeniyle oluşan sıcaklık artışı
Dengesiz Yük Dağılımı	Fren sistemlerinde tek taraflı ısınma, hidrolik sistemlerde basınç dengesizliği
İzolasyon Bozulması	Kablo izolasyonlarının yıpranması sonucu noktasal sıcaklık artışı
Sürtünme Artışı	Rulman, yatak veya kompozit parçalardaki sürtünmeden kaynaklı ısı yükselmesi
Soğutma Problemleri	Motor ya da elektronik sistemlerde yetersiz soğutma kaynaklı genel ısı yükselmesi

3.3.3.3. Kullanılan cihazlar ve yöntemler

- **Kızılötesi (IR) kameralar:** Temassız sıcaklık ölçümüne olanak tanır.
- **Termografi yazılımları:** Renkli ısı haritaları oluşturur ve analiz eder.
- **Zaman serisi termal izleme:** Ani sıcaklık değişimlerinin takibini sağlar.
- **Otomatik eşik belirleme ve alarm sistemleri:** Tehlikeli sıcaklık değişimleri için erken uyarı mekanizması sağlar.

Yapay zeka destekli kullanımında görüntü işleme algoritmaları ile sıcaklık haritalarında anomali tanıma, sıcaklık dağılımlarına göre karar destek sistemleri, SCADA entegrasyonu ile sürekli izleme ve bakım planlaması, derin öğrenme ile farklı arıza tiplerinin otomatik tanısı gibi süreçler işletilebilir.

3.3.4. Ultrasonik analiz

Ultrasonik analiz, yüksek frekanslı ses dalgalarının kullanılması yoluyla ekipman içindeki yapısal bozulmaların ve gaz/sıvı kaçaklarının tespit edilmesini sağlayan gelişmiş bir kestirimci bakım yöntemidir. Uçaklarda özellikle basınçlı sistemler, sızdırmazlık elemanları, kompozit yapıların iç kusurları ve elektriksel ark oluşumu gibi problemlerin belirlenmesinde önemli rol oynar.

3.3.4.1. Kullanım alanları

Havacılıkta ultrasonik analiz aşağıdaki alanlarda yaygın olarak kullanılmaktadır:

- Yakıt ve hava basınç hatlarında kaçak tespiti
- Hidrolik devrelerde sızdırmazlık kontrolü
- Elektrik sistemlerinde kıvılcım ve ark oluşumu algılama
- Kompozit malzemelerde iç çatlak ve boşlukların analizi
- Bağlantı elemanlarında gevşeklik kontrolü

3.3.4.2. Tespit edebileceği yaygın arızalar

Tablo 3.4’de, ultrasonik analiz yöntemi ile tespit edilebilecek başlıca arıza türleri sunulmuştur:

Tablo 3.4. Ultrasonik analizinin tespit edebileceği yaygın arıza türleri

Arıza Türü	Açıklama
Gaz Kaçağı	Yüksek basınçlı hatlarda veya bağlantı noktalarında sesli kaçak oluşumu
Sıvı Kaçağı	Hidrolik sistemlerde conta veya valf kaçaqları nedeniyle oluşan ses paternleri
Elektriksel Ark	Yüksek voltajlı sistemlerde yalıtım zayıflığı sonucu oluşan mikrokıvılcımlar
İç Kusurlar	Kompozit veya metal parçalar içinde boşluk, delaminasyon veya çatlak oluşumu
Gevşeklik	Cıvata, somun gibi bağlantı elemanlarının mikro hareketleriyle oluşan ultrasonik titreşimler

3.3.4.3. Kullanılan cihazlar ve yöntemler:

- Ultrasonik dinleme cihazları (contact probe ve airborne sensors)
- Spektrum analizörleri ve frekans tarayıcıları
- Ses dalgası yankı süresi ile kusur tespiti
- Yüzey altı yapıların görüntülenmesi için A-scan ve B-scan teknikleri

Yapay zekâ destekli uygulamalarda, ultrasonik sinyal desenlerinden arıza sınıflandırması yapılabilir (örneğin makine öğrenmesi tabanlı algoritmalar). Spektrum analizi yardımıyla otomatik karar destek sistemleri kurulabilir. Ayrıca SCADA entegrasyonu ile eşik geçişlerinin izlenmesi sağlanır ve zaman serisi analizleriyle kusur ilerleme trendleri tahmin edilerek bakım süreçleri daha etkin biçimde planlanabilir.

3.3.5. Akustik emisyon analizi

Akustik emisyon analizi, malzemelerdeki mikro düzeydeki deformasyonlar, çatlak ilerlemeleri ve sürtünme sonucu ortaya çıkan enerji boşalmalarını tespit etmek için kullanılan bir kestirimci bakım yöntemidir. Uçak yapılarında, özellikle kompozit malzemeler, rulmanlar, bağlantı noktaları ve iniş takımı gibi kritik bölgelerde erken hasar tespiti sağlamak amacıyla uygulanır. Yöntem, malzeme içerisinden yayılan yüksek frekanslı ses dalgalarının (ultrasonik) özel sensörlerle tespit edilmesi prensibine dayanır.

3.3.5.1. Kullanım alanları

Akustik emisyon analizi, havacılıkta şu alanlarda yaygın olarak kullanılmaktadır:

- Uçak gövdesi ve kanat panelleri (özellikle kompozit malzemeler)
- İniş takımı bağlantıları ve hidrolik sistem bileşenleri
- Rulmanlar ve döner parçalarda çatlak tespiti
- Basıncı tanklar ve yapısal bileşenler
- Motor bileşenlerinde yüksek sıcaklık stres izleme

3.3.5.2. Tespit edebileceği yaygın arızalar

Tablo 3.5, akustik emisyon analizinin tespit edebileceği başlıca arıza türlerini göstermektedir.

Tablo 3.5. Akustik emisyon analizinin tespit edebileceği yaygın arıza türleri (Grosse ve diğerleri, 2021)

Arıza Türü	Açıklama
Mikro çatlak oluşumu	Yük altında zorlanan bölgelerde gözle görünmeyen çatlak başlangıcı
Delaminasyon	Kompozit tabakalar arasındaki ayrışma süreci
Plastik deformasyon	Malzeme sınırlarının aşılmasıyla oluşan kalıcı şekil değişiklikleri
Sürtünme kaynaklı hasar	Bağlantı noktalarında gevşeklik sonucu yüzey sürtünmeleri
Ani kırılmalar	Aşırı yük veya yorulma nedeniyle oluşan hızlı hasar oluşumları

3.3.5.3. Kullanılan cihazlar ve yöntemler

- Yüzeye özel AE (Acoustic Emission) sensörleri monte edilir.
- Malzeme içerisindeki yüksek frekanslı ses dalgaları sensörlerle tespit edilir.
- Sinyaller zaman domeninde analiz edilir. (amplitüd, frekans, enerji)
- Kaynak lokasyonu üçgenleme yöntemiyle belirlenir.
- Eşik değeri aşan sinyaller alarm olarak değerlendirilir.

Yapay zekâ ile entegrasyon durumunda, sinyal karakteristiklerinden faydalanarak makine öğrenmesi modelleri, arıza türlerini sınıflandırabilir. SCADA sistemine entegre edilen AE analizleri, gerçek zamanlı izleme ve karar destek sunabilir. Ayrıca zaman içinde oluşan değişimler üzerinden bakım önerileri geliştirilebilir.

3.4. SCADA Sistemleri ile Kestirimci Bakımın Entegrasyonu

Modern kestirimci bakım sistemlerinde verilerin toplanması ve izlenmesi için SCADA sistemleri sıklıkla kullanılmaktadır. SCADA ile entegre çalışan PdM sistemleri, sensörlerden gelen verileri sürekli toplayarak veri tabanlarında işler ve belirlenen eşik değerlerin dışına çıktığında operatöre uyarı gönderir. SCADA sistemleri aracılığıyla, uçak bakım süreçleri sürekli olarak izlenebilir ve bakım gereksinimleri daha hızlı ve doğru şekilde belirlenebilir.

Tipik bir SCADA–PdM entegrasyon süreci aşağıdaki adımlardan oluşur:

- RTU/PLC sistemleri üzerinden SCADA'ya bağlı sensörlerden veri toplanır.
- SCADA yazılımı bu verileri işler ve ilgili kestirimci bakım algoritmasına aktarır.
- Tahmin algoritmaları (AI/ML (Artificial Intelligence / Machine Learning) arıza olasılıklarını hesaplar.
- Anormal veriler, operatör paneline ya da bakım sistemine uyarı olarak gönderilir.

Havacılık sektöründe bakım süreçlerinin etkinliği, uçuş güvenliği ve operasyonel süreklilik açısından hayati öneme sahiptir. Geleneksel bakım yaklaşımlarında (planlı/periodyk bakım veya arıza sonrası bakım), arızaların önceden tahmin edilmesi mümkün olmadığından hem maliyetli hem de zaman kaybettirici durumlarla karşılaşmaktadır. Bu noktada kestirimci bakım (predictive maintenance), sistemde oluşabilecek arızaları önceden tahmin ederek bakım faaliyetlerini optimize etmeyi amaçlar. Bu yaklaşımın başarısı ise gerçek zamanlı ve doğru veriye bağlıdır. Bu bağlamda SCADA (Supervisory Control and Data Acquisition) sistemleri büyük rol oynamaktadır.

SCADA ile kestirimci bakımın entegrasyonu şu avantajları sağlamaktadır:

Gerçek Zamanlı Veri Toplama ve İzleme: Motor sıcaklığı, titreşim, basınç gibi kritik veriler SCADA ile anlık olarak toplanır. Bu durum, kestirimci bakım algoritmalarının canlı verilerle çalışmasına olanak tanır.

Yüksek Hızda Karar Desteği: Eşik değerlerinin aşılması durumunda SCADA sistemleri anında alarm verir. Bu, kestirimci model çıktıları ile birleştirilerek hızlı müdahale imkânı sağlar.

Tarihsel Veri ve Öğrenen Sistemler: SCADA sistemlerinin arşivlediği veriler, yapay zeka algoritmalarının eğitilmesi için kullanılır. Bu sayede modellerin doğruluğu artar.

Eşik Değeri Yönetimi: SCADA sistemleri ile belirlenen eşik değerler, kestirimci algoritmalarla entegre edilerek arıza sinyalleri daha doğru sınıflandırılır.

Otomasyon ve Dijitalleştirme: SCADA sistemi kestirimci analiz sonucuna göre operatörü bilgilendirir ya da otomatik bakım emri üretir. Bu da insan hatasını en aza indirir.

Maliyet Avantajı: Arızalar gerçekleşmeden önce müdahale edilmesi plansız duruşları ve yüksek onarım maliyetlerini azaltır.

Literatürde SCADA sistemlerinin kestirimci bakım yaklaşımlarıyla entegrasyonunun, tahmin doğruluğunu ve sistem güvenilirliğini artırdığı belirtilmiştir. Özellikle gerçek zamanlı veri akışı sayesinde makine öğrenmesi modelleri daha doğru kararlar verebilmekte, bu da arızaların erken tespiti ve bakım planlamasında verimlilik sağlamaktadır (Lee ve diğerleri 2015; Bampoula ve diğerleri, 2021)

SCADA tabanlı sistemlerde kestirimci bakım uygulamaları, süreç verilerinin anlık toplanarak analiz edilmesini mümkün kılmakta ve bakım stratejilerinin dijitalleşmesine öncülük etmektedir. Bu bağlamda Suryadarma ve Ai (2020), SCADA destekli endüstrilerde kestirimci bakımın mevcut durumunu literatür açısından değerlendirerek, bu entegrasyonun sağladığı operasyonel avantajlara dikkat çekmiştir.

SCADA tabanlı kestirimci bakım sistemleri, rüzgar türbinleri gibi büyük veri üreten endüstriyel varlıkların bakımında başarılı sonuçlar vermektedir. Udo ve Muhammad (2021), SCADA verilerini kullanarak veri odaklı makine öğrenmesi teknikleriyle arızaların önceden tahmin edilebildiğini ve bu sayede sistem verimliliğinde önemli artışlar sağlandığını göstermiştir.

Eriksson (2020), rüzgar türbinlerinden elde edilen SCADA verileriyle makine öğrenimi modellerini eğiterek, kestirimci bakım stratejilerinin gerçek zamanlı uygulanabilirliğini ortaya koymuştur.

3.5. Kestirimci Bakımda Kullanılan Veri Analizi ve Yorumlama Teknikleri

Kestirimci bakım yöntemleriyle elde edilen verilerin analiz edilmesi için çeşitli teknikler ve algoritmalar kullanılır. Bu yöntemler arasında istatistiksel analiz, spektral analiz, makine öğrenmesi ve yapay zekâ algoritmaları bulunur. Bu analiz yöntemleri sayesinde ekipmanın durum değerlendirmesi ve kalan ömür tahmini yapılabilir, böylece bakım faaliyetlerinin planlanması ve maliyet etkinliği artırılır. Analizlerin teknik özellikleri aşağıda özetlenmiştir.

3.5.1. İstatistiksel analiz

İstatistiksel analiz, sistemden toplanan verilerin istatistiksel yöntemlerle işlenerek arıza belirtilerinin ortaya çıkarılmasına dayanan bir kestirimci bakım yaklaşımıdır. Ortalama, varyans, standart sapma, regresyon analizi ve dağılım testleri gibi tekniklerle uçak sistemlerinde sapmalar tespit edilebilir.

3.5.1.1. Kullanım alanları

İstatiksel analizin kullanım alanları aşağıda belirtilmiştir.

- Sıcaklık, basınç ve titreşim gibi sürekli izlenen parametrelerde normal dışı davranışların belirlenmesi
- Motor performansının zamana bağlı olarak izlenmesi
- Hidrolik sistemlerin stabilite değerlendirmesi ve sızıntı öncesi uyarı sistemleri

3.5.1.2. Tespit edebileceği arızalar

İstatiksel analizin tespit edebileceği arızalar Tablo 3.6’da sunulmaktadır.

Tablo 3.6. İstatistiksel analizin tespit edebileceği yaygın arıza türleri (Mobley, 2002)

Arıza Türü	Açıklama
Performans Sapmaları	Sistem parametrelerinde ortalama değerlerden sapmalar
Aşırı Dalgalanma	Basınç veya sıcaklık gibi sinyallerde istatistiksel sınırların aşılması
Trend Değişimleri	Zamanla bozulan sistem davranışı

3.5.1.3. Analiz yöntemi ve ölçüm süreci

- Sensörlerden gelen veriler sürekli olarak kaydedilir.
- Ortalama, varyans, standart sapma gibi temel istatistiksel değerler hesaplanır.
- Zaman serisi analizi ve regresyon teknikleri kullanılarak eğilim ve sapmalar belirlenir.
- Kontrol grafikleri ve eşik tabanlı uyarı sistemleriyle potansiyel anomaliler tespit edilir.

3.5.1.4. Avantajları

- Uygulaması kolay ve hesaplama maliyeti düşüktür.
- Gerçek zamanlı izleme sistemleriyle entegre edilebilir.
- Anomali tespitinde ilk basamak olarak kullanılır.

3.5.2. Spektral analiz

Spektral analiz, titreşim ve akustik sinyallerin frekans bileşenlerine ayrılarak incelenmesini sağlayan güçlü bir kestirimci bakım yöntemidir. Özellikle uçak motorları, rulmanlar, fanlar, kompresörler ve diğer döner makinelerde, mekanik arızaların erken teşhisi için kullanılır. Bu yöntemde, zaman domeninde elde edilen sinyaller, Fourier dönüşümü kullanılarak frekans domainine çevrilir ve spektrum grafikleri üzerinden analiz edilir.

Spektral analiz, titreşimin temel kaynaklarını ayırt etmeye yardımcı olur; örneğin balansızsızlık, eksenel kaçıklık, gevşeklik ve rulman arızaları gibi sorunların her biri farklı frekans bileşenleriyle ilişkilendirilebilir.

3.5.2.1. Kullanım alanları

Spektral analizinin kullanım alanları aşağıda belirtilmiştir.

- Rulman ve dişli kutularındaki mekanik arızaların tespiti
- Fan, kompresör ve elektrik motorlarında döner elemanların denetimi
- Titreşim kökenli sistem dengesizliklerinin belirlenmesi

3.5.2.2. Tespit edebileceği arızalar

Spektral analizinin tespit edebileceği arızalar Tablo 3.7’de sunulmaktadır.

Tablo 3.7. Spektral analizinin tespit edebileceği yaygın arıza türleri (Randall, 2011)

Arıza Türü	Açıklama
Balanssızlık	Frekans spektrumunda $1 \times \text{RPM}$ tepe değeri
Rulman Arızası	Yüksek frekans bileşenlerinin artışı
Eksenel Kaçıklık	$2 \times \text{RPM}$ harmoniklerinin belirginleşmesi

3.5.2.3. Analiz yöntemi ve ölçüm süreci

- Titreşim verileri, zaman domaininde sensörlerle toplanır.
- Hızlı Fourier Dönüşümü (FFT) uygulanarak frekans domainine dönüştürülür.
- Spektrum grafikleri üzerinde tepe frekanslar analiz edilir.
- Zaman içinde değişim gösteren frekans trendleri izlenerek, arızaların gelişimi değerlendirilir.

3.5.2.4. Avantajları

- Döner ekipmanlardaki arızaların yüksek doğrulukla ve erken aşamada tespiti sağlanır.
- Güçlü matematiksel temel ile objektif sonuçlar üretir.
- SCADA sistemlerine kolay entegre edilebilir ve otomatik yorumlama yapılabilir.

3.5.3. Makine öğrenmesi

Makine öğrenmesi, sistemin geçmiş verilerden öğrenerek gelecekteki davranışları tahmin etmesini sağlayan bir yapay zekâ alt dalıdır. Bakımda özellikle arıza tahmini, sınıflandırma ve regresyon görevlerinde kullanılır. Gözetimli, gözetimsiz ve pekiştirmeli öğrenme yöntemleri vardır.

3.5.3.1. Kullanım alanları

Makine öğrenmesinin kullanım alanları aşağıda belirtilmiştir.

- Arıza sınıflandırma
- Kalan ömür tahmini (RUL - Remaining Useful Life)
- Anomali tespiti

3.5.3.2. Tespit edebileceği arızalar

Makine öğrenmesinin tespit edebileceği arızalar Tablo 4.8’de sunulmuştur.

Tablo 3.8. Makine öğrenmesinin tespit edebileceği yaygın arıza türleri (Susto ve diğerleri, 2014; Arena ve diğerleri, 2024)

Arıza Türü	Açıklama
Motor Arızaları	Veri örüntülerinden motor davranışının öğrenilmesi
Yatak Hasarları	Sensör verileri ile öğrenilen titreşim desenleri
Sensör Anomalileri	Gözetimsiz öğrenme ile fark edilen veri sapmaları

3.5.3.3. Analiz yöntemi ve ölçüm süreci

- Veri ön işleme: Gürültü giderme, normalizasyon, eksik veri tamamlama
- Özellik çıkarımı (feature extraction): Spektral, istatistiksel ve zaman domeninde özelliklerin elde edilmesi
- Model eğitimi: Random Forest, SVM (Destek Vektör Makineleri), XGBoost, Yapay Sinir Ağları (ANN) gibi algoritmalarla model oluşturma
- Gerçek zamanlı tahmin: Eğitilmiş modelin canlı veriler üzerinde uygulanması
- Model güncelleme: Yeni verilerle modelin sürekli olarak yeniden eğitilmesi (online learning)

3.5.3.4. Avantajları

- Karmaşık ilişkileri öğrenebilir.
- Yüksek doğrulukla arıza tahmini yapılabilir.
- Veriye dayalı karar destek sistemlerine katkı sağlar.

3.5.4. Yapay zeka algoritmaları

Yapay zekâ algoritmaları, klasik yazılımsal mantığın ötesinde karar verebilen, öğrenebilen ve genelleyeabilen sistemlerdir. Derin öğrenme, sinir ağları, bulanık mantık ve genetik algoritmalar gibi yöntemler uçak bakım süreçlerinde gelişmiş kestirimci bakım çözümleri sunmaktadır.

3.5.4.1. Kullanım alanları

Yapay zekanın kullanım alanları aşağıda belirtilmiştir.

- Kompleks sistemlerde arıza tanısı
- Görsel verilerle hasar tespiti
- Gömülü sistemlerde gerçek zamanlı karar mekanizmaları

3.5.4.2. Tespit edebileceği arızalar

Yapay zekanın tespit edebileceği arızalar Tablo 3.9’da sunulmuştur.

Tablo 3.9. *Yapay zeka algoritmalarının tespit edebileceği yaygın arıza türleri (Carvalho ve diğerleri, 2018)*

Arıza Türü	Açıklama
Kompleks Sistem Arızaları	Çok değişkenli verilerde ilişkisel analiz ile tespit
Görsel Anomaliler	Termal, görsel veya yapısal veri analizi
Çoklu Arıza Durumları	Sistemler arası korelasyon ile tahmin

3.5.4.3. Analiz yöntemi ve ölçüm süreci

Yapay zekâ tabanlı kestirimci bakım süreçlerinde analiz şu şekilde gerçekleştirilir:

- Veri toplama: SCADA sistemleri ve IoT cihazları üzerinden çoklu sensör verileri toplanır.
- Veri ön işleme: Eksik verilerin tamamlanması, veri temizleme ve normalizasyon işlemleri yapılır.

3.5.4.4. Modelleme süreci

- Derin öğrenme (Deep Learning): CNN, RNN, LSTM gibi modeller kullanılarak karmaşık örüntüler öğrenilir.
- Genetik algoritmalar: Optimizasyon ve ömür tahmin problemlerinde kullanılır.
- Bulanık mantık sistemleri: Belirsizlik içeren durumlarda arıza risk puanlaması yapılır.
- Gerçek zamanlı analiz: Uçuş sırasında veya bakım öncesi veriler anlık değerlendirilir.
- Öneri sistemi: Tahmin edilen arızalara karşı otomatik bakım planı oluşturulur.

3.5.4.5. Avantajları

- Yüksek doğruluk ve genelleme yeteneği: Karmaşık ve doğrusal olmayan sistem davranışlarını öğrenebilir.
- Veri tipinden bağımsız analiz: Sayısal, görsel, termal ve metinsel verilerle entegre çalışabilir.
- Otonom karar alma kabiliyeti: Minimum insan müdahalesi ile sürekli bakım değerlendirmesi yapılabilir.

- Operasyonel verimlilik: Bakım süreçlerini optimize ederek uçuş güvenliğini ve sistem sürekliliğini artırır.

3.5.4.6. *Yapay zekâ destekli kestirimci bakım*

Günümüzde uçak bakım süreçlerinde, sistem performansını izleyerek arızaları öngörmeyi amaçlayan birçok yöntem kullanılmaktadır. Bu yöntemler arasında istatistiksel analiz, spektral analiz ve geleneksel regresyon modelleri önemli rol oynamaktadır. Ancak, bu teknikler genellikle belirli hipotezlere ve sınırlı değişken analizlerine dayanır. Buna karşın yapay zekâ (AI), karmaşık örüntüleri öğrenme ve çok boyutlu verileri işleme konusundaki üstünlüğü ile kestirimci bakımda devrim niteliğinde bir dönüşüm sağlamaktadır.

Yapay zekâ, karmaşık verilerden anlamlı örüntüler çıkarma ve bu örüntüler doğrultusunda kararlar alma becerisi sayesinde kestirimci bakım uygulamalarında önemli bir rol oynamaktadır. SCADA sistemleri aracılığıyla toplanan büyük hacimli sensör verileri, yapay zeka algoritmaları ile analiz edilerek olası arızalar daha meydana gelmeden önce öngörülebilir hale gelmektedir.

PdM, özellikle büyük veri ile beslendiğinde daha güçlü hale gelir. Bu noktada yapay zekâ algoritmaları öne çıkar:

- **Makine Öğrenimi:** Geçmiş arıza verilerinden öğrenerek yeni verilerle tahmin yapar (örneğin karar ağaçları, SVM, random forest).
- **Derin Öğrenme:** Büyük veri kümeleri ile karmaşık modeller kurar. Uçak motor verilerinden öğrenen sinir ağları, erken uyarı sistemlerinde kullanılır.
- **Anomali Tespiti:** Normal dışı verileri belirler ve arıza oluşmadan önce uyarı verir.

Örnek: Airbus, bulut tabanlı Skywise platformu aracılığıyla motor ve sistem verilerini gerçek zamanlı olarak analiz ederek, bazı uçak bileşenlerinde kesintisiz bakım olanağı sunmaktadır. Delta Air Lines ile yapılan iş birliğinde, Skywise sisteminin operasyondaki aksaklıkları (unscheduled events) bileşen bazında yaklaşık %15 azaltabildiği rapor edilmiştir (Airbus and Delta TechOps, Aviation Week, 2021).

Yapay zeka algoritmalarının kestirimci bakım süreçlerine entegrasyonu, sistematik olarak incelendiğinde, arıza öngörülerinde doğruluk artışı ve bakım kararlarında daha kısa yanıt süreleri sağladığı görülmektedir. Scaife (2024), kapsamlı bir sistematik

derlemesinde, özellikle endüstriyel bakım sistemlerinde yapay zekanın arıza tespiti, bakım optimizasyonu ve maliyet azaltımı konularında önemli kazanımlar sağladığını ortaya koymuştur.

3.6. Literatürde Kestirimci Bakım Uygulamaları

Havacılık sektöründe kestirimci bakım (PdM) uygulamalarının etkinliğini ortaya koyan birçok akademik çalışma bulunmaktadır. Bu çalışmalar, PdM'nin yalnızca bakım maliyetlerini azaltmakla kalmayıp aynı zamanda operasyonel sürekliliği artırdığını ve uçuş güvenliğine doğrudan katkı sağladığını göstermektedir. Literatürde yer alan bazı dikkat çekici bulgular aşağıda özetlenmiştir:

- Kestirimci bakım yöntemi geleneksel zaman tabanlı bakım stratejilerine kıyasla daha düşük maliyet, daha az plansız duruş ve daha yüksek sistem güvenilirliği sağlamaktadır (Jardine ve diğerleri 2006; Lee ve diğerleri 2015, Mobley 2002).
- Jet motorları ve diğer havacılık sistemlerinde uygulanan yapay zekâ destekli kestirimci bakım yöntemleri, arızaların erken tespiti sayesinde planlanmamış bakım olaylarının azaltılmasına katkı sağlamaktadır. Literatürde yer alan çalışmalar, bu tür sistemlerin sürekli sensör verisiyle beslenen modeller aracılığıyla bakım süreçlerini optimize ettiğini ve bakım maliyetlerinde %15–25 aralığında azalma sağladığını göstermektedir (Li ve diğerleri, 2020; Bambang ve diğerleri, 2021).
- Makine öğrenmesi ve derin öğrenme teknikleri, özellikle zaman serisi analizi ve anomali tespiti alanlarında kestirimci bakımın başarısını artırmaktadır (Widodo ve Yang, 2007; Zhao ve diğerleri, 2017).
- Yapılan çalışmalar, kestirimci bakım algoritmalarının doğru uygulanması durumunda bakım maliyetlerinde %10–40 arasında azalma ve sistem kullanılabilirliğinde %20–50 arasında artış sağlanabildiğini göstermektedir (Carvalho ve diğerleri, 2019).
- Kestirimci bakım stratejilerinin uygulanabilirliği, uçak sistemlerinin fiziksel yapısı ve işlevsel karmaşıklığıyla doğrudan ilişkilidir. Özellikle aerodinamik yüzeyler, hidrolik ve yapısal sistemlerin düzenli takibi, bakımın zamanlamasında kritik rol oynamaktadır (TTS Integrated Training System, 2011).

3.7. Kestirimci Bakımın Havacılıkta Uygulama Kısıtları

Her ne kadar kestirimci bakım sistemleri birçok avantaj sunsa da, havacılık sektöründe bu teknolojilerin uygulanabilirliğini sınırlayan bazı temel zorluklar bulunmaktadır:

- **Yüksek İlk Yatırım Maliyeti:** Gelişmiş sensör sistemleri, veri toplama altyapısı ve yazılım platformlarının kurulumu yüksek maliyet gerektirir. Özellikle filoda çok sayıda uçak bulunan havayolu şirketleri için bu durum bütçesel bir kısıt oluşturabilir.
- **Uçak Modeline Özgü Veri Eksikliği:** Her uçak modelinin yapısı ve sistem dinamikleri farklıdır. Bu durum, genelleştirilebilir modellerin geliştirilmesini zorlaştırmakta ve model bazlı verilerin toplanmasını gerektirmektedir.
- **Yapay Zekâ Modellerinin Sınırlı Genelleme Yeteneği:** Eğitim verilerinin yetersizliği veya temsili olmaması durumunda, AI modelleri uçak performansındaki olağandışı durumları doğru şekilde öngöremeyebilir.
- **Nitelikli Teknik Personel Gereksinimi:** PdM sistemlerinin etkin bir şekilde çalışabilmesi için veri bilimciler, bakım mühendisleri ve SCADA uzmanlarından oluşan çok disiplinli ekiplerin oluşturulması gereklidir.
- **Bu kısıtların aşılabilmesi, teknoloji yatırımlarının stratejik olarak planlanması ve insan kaynağının sürekli eğitilmesi ile mümkündür.**

3.8. Gelecek Yönelimler

Havacılıkta kestirimci bakım uygulamalarının geleceği, dijitalleşme ve otonom sistem teknolojilerinin gelişimi ile şekillenmektedir. Önümüzdeki yıllarda öne çıkması beklenen yönelimler şu şekilde sıralanabilir:

- **Dijital İkiz (Digital Twin) Teknolojisi:** Uçağın dijital bir kopyasının oluşturularak simülasyon ortamında sistem davranışlarının izlenmesi ve sanal bakım senaryolarının test edilmesi mümkün hâle gelecektir.
- **IoT Tabanlı Mikro Sensör Sistemleri:** Uçak üzerindeki her bir bileşenin gerçek zamanlı olarak izlenmesini sağlayacak düşük maliyetli, kablosuz sensör sistemlerinin kullanımı artacaktır.

- Otonom Bakım Sistemleri: Yapay zekâ destekli algoritmalar sayesinde uçaklar, kendi sistem verilerini analiz ederek potansiyel arızaları tespit edebilecek ve otomatik bakım talebi oluşturabilecektir.

Otonom kestirimci bakım sistemlerinin uygulandığı tesislerde, insan kaynaklı hataların azaldığına dair literatürde artan sayıda bulgu bulunmaktadır. Özellikle sensör tabanlı sürekli izleme sistemleri ve yapay zekâ destekli karar mekanizmalarının, manuel müdahale ihtiyacını azaltarak bakım süreçlerindeki operatör hatalarını sınırladığı ifade edilmektedir (Zonta ve diğerleri, 2020; Lee ve diğerleri, 2014). Bu bağlamda, kestirimci bakım sistemlerinin yalnızca arıza tahmini ve maliyet yönetimi değil, aynı zamanda güvenlik performansı açısından da katkı sağladığı belirtilmektedir (Carvalho ve diğerleri, 2019; Ahmad ve diğerleri, 2014)

Xiong, Wang, Fu ve Xu (2021), dijital ikiz teknolojisi kullanarak geliştirilen uçak motor tabanlı kestirimci bakım sistemlerinin, bakım etkinliğini artırarak havacılık motorlarında arıza öncesi müdahale imkânı sağladığını ve sistem sürekliliğini önemli ölçüde geliştirdiğini ortaya koymuştur

Sonuç olarak, kestirimci bakım uygulamaları yalnızca ekonomik avantaj sağlamakla kalmaz, aynı zamanda uçuş güvenliğini doğrudan etkileyen kritik bir süreçtir. Havacılıkta PdM sistemlerinin daha yaygın kullanımı; dijitalleşme, yapay zekâ ve SCADA teknolojilerinin entegrasyonu ile mümkün olacaktır.

4. ÖNERİLEN SCADA YAKLAŞIMI

SCADA (Supervisory Control and Data Acquisition - Denetleyici Kontrol ve Veri Toplama) sistemleri, endüstriyel süreçlerin merkezi bir konumdan izlenmesini, kontrol edilmesini ve verilerin gerçek zamanlı olarak analiz edilmesini sağlayan gelişmiş otomasyon sistemleridir. Bu bölümde SCADA sistemlerinin genel yapısı, temel bileşenleri, havacılıkta kullanımı ve karşılaşılan temel zorluklar incelenecektir.

4.1. SCADA Sistemlerinin Tanımı

SCADA (Supervisory Control and Data Acquisition), yani Denetleyici Kontrol ve Veri Toplama sistemleri; geniş coğrafi alanlara yayılmış endüstriyel tesislerin merkezi olarak izlenmesini, kontrol edilmesini ve otomatikleştirilmesini sağlayan bütünlük sistemlerdir. Bu sistemler, üretim, iletim ve dağıtım gibi süreçlerin dijital ortamda yönetilmesine olanak tanıyarak insan hatalarını azaltır, verimliliği artırır ve sistemlerin

güvenliğini sağlar. SCADA sistemleri ilk olarak enerji, su ve doğal gaz sektörlerinde kullanılmaya başlanmış, daha sonra ulaşım, üretim ve özellikle havacılık gibi yüksek hassasiyet gerektiren alanlara da uyarlanmıştır.

SCADA sistemleri, endüstriyel süreçlerin merkezi olarak izlenmesi ve kontrol edilmesini sağlayan yapılar olup, modern endüstride operasyonel verimlilik, güvenlik ve sürekli üretim açısından kritik öneme sahiptir. Jeff (2005), SCADA'nın temel işlevlerini, bileşenlerini ve evrimsel gelişimini detaylandırarak bu sistemlerin otomasyon mimarisindeki yerini açıklamaktadır.

4.2. SCADA Sistemlerinin Tarihçesi ve Gelişimi

SCADA sistemlerinin ilk örnekleri 1960'lı yıllarda, analog verilerin merkezi bir bilgisayara aktarılmasıyla ortaya çıkmıştır. İlk nesil SCADA sistemleri yalnızca veri toplama işlevine sahipken, sonraki dönemlerde ağ teknolojilerinin, yazılımların ve kontrol algoritmalarının gelişmesiyle birlikte çok daha etkileşimli ve akıllı hale gelmiştir. Modern SCADA sistemleri artık yapay zekâ, makine öğrenimi, bulut tabanlı analiz, nesnelerin interneti (IoT) ve dijital ikiz gibi kavramlarla entegre bir şekilde çalışmaktadır. Havacılıkta ise bu evrimsel gelişme, bakım süreçlerinin gerçek zamanlı takibini ve kestirimci analizlerin uygulanmasını mümkün kılmıştır.

4.3. SCADA Sistemlerinin Yapısı ve Temel Bileşenleri

SCADA sistemleri, dağıtılmış bir ağ üzerinde bulunan uzaktaki cihazlarla iletişim kurarak, saha cihazlarından veri toplar, bu verileri analiz eder ve süreçleri kontrol eder. Tipik olarak, SCADA sistemleri sensör ve aktüatörlerden gelen verileri toplar, bunları merkezi bir kontrol odasında görsel arayüzler aracılığıyla sunar ve operatörlere gerçek zamanlı izleme, kontrol ve raporlama imkanı sağlar.

SCADA sistemleri genellikle büyük ölçekli endüstriyel tesislerde, enerji şebekelerinde, su ve atık su arıtma tesislerinde, petrol ve gaz endüstrisinde, taşımacılık sistemlerinde, hava trafik kontrolünde ve diğer benzer endüstrilerde kullanılır. Bu sistemler, süreçlerin güvenli ve verimli bir şekilde çalışmasını sağlar, hata ve arızaları tespit eder, alarm oluşturur ve operatörlere müdahale imkanı verir.


SCADA sistemleri genellikle üç ana bileşenden oluşur: Veri Toplama Üniteleri, İletişim Ağı ve Protokolleri ile Veri İzleme ve Kontrol Merkezi. Bu 3 ana bileşeni ve SCADA İşletim sistemini de aşağıda açıklayalım.

Otomasyon sistemleri; sensör, aktüatör, kontrol birimi, haberleşme altyapısı ve kullanıcı ara yüzü gibi birçok bileşenin entegre çalışmasıyla işlevsel hale gelir. Karaçor ve Keleş (2007), endüstriyel otomasyon sistemlerinin yapısal bileşenlerini detaylandırarak, bu yapıların SCADA gibi üst düzey kontrol sistemlerine temel oluşturduğunu belirtmiştir.

Daneels ve Salter (1999), SCADA mimarisinin temel bileşenlerini ve fonksiyonlarını sistematik olarak açıklamış ve bu sistemlerin endüstriyel otomasyonun vazgeçilmez parçaları haline geldiğini vurgulamıştır.

4.3.1. Veri toplama üniteleri (RTU ve PLC)


SCADA sistemlerinin saha seviyesinde kullanılan veri toplama cihazları, RTU (Remote Terminal Unit - Uzak Terminal Ünitesi) ve PLC (Programmable Logic Controller - Programlanabilir Mantıksal Denetleyici) olarak adlandırılır. RTU ve PLC'ler, sensörlerden aldıkları verileri dijital hale getirerek merkezi kontrol merkezine iletirler. Şekil 4.1'de tipik SCADA ve veri toplama mimarisi gösterilmiştir.



Şekil 4.1. Örnek SCADA veri toplama mimarisi

PLC (Programlanabilir Mantıksal Denetleyici – Programmable Logic Controller): PLC'ler, endüstriyel otomasyon uygulamalarında yaygın olarak kullanılan programlanabilir kontrolörlerdir. Sahadaki sensörlerden gelen verileri alır, bu veriler üzerinde önceden tanımlanmış mantıksal işlemleri uygular ve ilgili aktüatörlere komutlar

gönderir. SCADA sistemleri, PLC'ler aracılığıyla hem süreçleri kontrol eder hem de gerçek zamanlı veri toplar.



Şekil 4.2. Örnek RTU ve PLC görseli

RTU (Remote Terminal Unit): RTU'lar, sahadaki veri toplama birimleri arasında yer alan cihazlardır. Genellikle uzak bölgelerde veya zor erişilebilen yerlerde kullanılırlar. RTU'lar, sensörlerden gelen verileri toplar, bu verileri işler ve iletişim ağı üzerinden SCADA sistemine aktarır. Ayrıca, SCADA sisteminden gelen komutları alarak, sahadaki ekipmanlara iletir.


SCADA sistemleri, PLC'ler ile entegre şekilde çalışarak endüstriyel otomasyonun omurgasını oluşturur. Rajesh ve Vikrant (2016), bu sistemlerin teorik temellerini ve pratik uygulamalarını kapsamlı biçimde açıklayarak SCADA'nın saha düzeyinden kontrol merkezine kadar olan veri akışını detaylandırmıştır.

Bayındır ve diğerleri (2011), bir sıvı depolama sistemi üzerinde PLC ve SCADA entegrasyonu ile gerçek zamanlı seviye, sıcaklık ve basınç izleme sistemini geliştirmiştir. Deneysel sonuçlar sistemin daha maliyet-etkin, hassas ve güvenilir olduğunu göstermiştir.

4.3.2. İletişim ağı ve protokolleri


İletişim ağı, sahadaki cihazlarla (PLC, RTU vb.) kontrol merkezi arasındaki veri iletimini sağlayan altyapıdır. Bu iletişim genellikle kablolu veya kablosuz iletişim protokolleri kullanılarak gerçekleştirilir. Şekil 4.3'te kablolu haberleşme altyapısına, Şekil 6.4'te ise kablosuz haberleşme altyapısına örnekler verilmiştir. Bir sonraki bölümde

anlatılacak olan haberleşme protokolleri sayesinde SCADA ile cihazlar (PLC/RTU) arasında veri alışverişi sağlanmaktadır.



Şekil 4.3. Örnek SCADA ile veri toplama cihazları arasındaki kablolu haberleşme altyapısı

Şekil 4.3’de gösterilen kablolu haberleşme altyapısı genelde tesiste bulunan Lokal SCADA sistemleri için kullanılır. Tesiste bulunan veri toplama cihazları ile SCADA arasında bir kablolu haberleşme altyapısı kurulur. Bu tip haberleşme altyapısı genellikle tesis bünyesinde kurulan lokal SCADA haberleşmelerinde kullanılabildiği gibi enerji SCADA uygulamalarında, merkez SCADA bulunuyorsa tesis ile merkez arasında da kablolu altyapı kurulabilmektedir. Bu yöntem, uçaklarda kokpite SCADA sisteminin kurulmasının ardından, uçakta bulunan veri toplayıcılar ile SCADA sistemi arasında kablolu bağlantı kurularak da uygulanabilir.




Şekil 4.4. SCADA ile veri toplama cihazları arasındaki kablosuz haberleşme altyapısı

Yukarıda Şekil 4.4’de gösterilen kablosuz haberleşme altyapısı ise genellikle Merkez SCADA ile veri toplayıcılar arasında kullanılır. Bu yöntem birden fazla veri toplayıcı ile merkez SCADA arasında iletişimi sağlayarak verilerin güvenli bir şekilde SCADA sistemine iletilmesini sağlar. Hava trafik kontrol merkezinde kurulacak bir SCADA sistemi aracılığıyla, havaalanları veya uçaklarda bulunan veri toplayıcılardan veriler alınabilir.

SCADA sistemleri, endüstriyel otomasyonun bir parçası olarak, süreçlerin daha etkin yönetilmesini, enerji ve kaynak tasarrufunu, operasyonel güvenliğini artırmayı ve arızaların önceden tespit edilmesini sağlar.

Kablosuz haberleşme teknolojilerinin enerji otomasyon sistemlerine entegrasyonu, özellikle dağınık coğrafyalarda yer alan kritik altyapıların merkezi olarak izlenmesini ve kontrol edilmesini mümkün kılmaktadır. Özer (2009), Van ilinde gerçekleştirdiği çalışmada, kablosuz iletişim destekli bir enerji otomasyonu tasarlayarak, bu teknolojilerin saha verilerinin gerçek zamanlı toplanması ve değerlendirilmesinde nasıl etkili kullanılabileceğini ortaya koymuştur.

SCADA sistemlerinde kullanılan endüstriyel haberleşme protokolleri, sahadaki veri toplama birimleriyle kontrol merkezi arasındaki iletişimi sağlamak için kullanılır. Şekil 4.5’te veri toplama birimiyle kontrol merkezi arasında örnek haberleşme protokolleri gösterilmiştir. Bu protokoller, güvenilir, hızlı ve uyumlu bir veri iletişimi sağlamak amacıyla özel olarak tasarlanmıştır. SCADA sistemlerinde yaygın olarak kullanılan bazı endüstriyel haberleşme protokolleri şunlardır:



Şekil 4.5. Haberleşme protokolü ile iletişim

DNP 3.0 haberleşme protokolü, endüstriyel otomasyon ve SCADA uygulamalarında kullanılan bir haberleşme protokolüdür. DNP3, uzaktaki veri toplama birimleri ile merkezi kontrol merkezi arasında güvenilir bir iletişim sağlar. Bu protokol, veri bütünlüğü, hata tespiti, zaman damgası ve diğer özelliklerle birlikte geniş bir veri noktası desteği sunar.

DNP 3.0 haberleşme protokolünün avantajı sahadaki cihaza sorgu yapıp verileri okumak yerine cihazda herhangi bir veri değişimi varsa veriyi SCADA'ya gönder diyebiliriz. Veri değişim aralığı, RTU/PLC programları yazılırken kullanıcı tarafından belirlenebilir. Bu değişim aralıkları, SCADA izleme noktaları üzerinden değiştirilebilir. Örneğin, uzaktan izleyen hava trafik kontrolü veya pilot anlık olarak yükseklik 0,1 feet değiştiğinde SCADA'ya veri göndermesini isterse bunu sağlayabilir. Ancak bunu kullanıcının inisiyatifine bırakmak havacılık sektöründe özellikle uçak izleme sistemlerinde insan hatasından dolayı güvenlik riskleri oluşturabilir. Bunun kademeli güvenlik seviyelerine göre yapılması daha uygun olabilir. Özetle DNP3 protokolünde değişim aralıkları istenirse değişim aralıkları, RTU/PLC yazılımlarına müdahale edilmeden veri komutları aracılığıyla değiştirilebilir.

SCADA sistemlerinde yaygın olarak kullanılan DNP3 protokolü, özellikle kritik altyapılarda güvenlik açısından önemli riskler barındırmaktadır. Qassim ve diğerleri (2023), DNP3 protokolüne yönelik gerçekleştirdikleri analizde, bu protokolün zafiyetlerini ortaya koyarak güvenlik önlemlerinin gerekliliğini vurgulamıştır.

Modbus haberleşme protokolü, SCADA sistemlerinde sıkça kullanılan bir haberleşme protokolüdür. Hem seri haberleşme (Modbus RTU) hem de Ethernet üzerinden haberleşme (Modbus TCP) için uygun versiyonları bulunur. Modbus, basit ve hafif bir protokol olup, genellikle PLC'ler ve diğer veri toplama birimleriyle kontrol merkezi arasındaki haberleşme için tercih edilir.

OPC (OLE for Process Control) haberleşme protokolü, SCADA ve endüstriyel otomasyon sistemlerinde farklı cihaz ve yazılımlar arasında uyumlu veri paylaşımı sağlamak amacıyla geliştirilmiş bir standarttır. OPC, veri toplama birimleri ve kontrol merkezi arasındaki iletişimi kolaylaştıran bir arayüz sağlar. OPC protokolü, farklı üreticilerin cihazlarının ve yazılımlarının birbirleriyle uyumlu bir şekilde çalışmasını sağlamak amacıyla geliştirilmiştir.

SCADA sistemlerinin, sahadan gerçek zamanlı veri toplayarak kestirimci bakım uygulamalarına temel oluşturabilecek şekilde yapılandırılması mümkündür. Özellikle

OPC tabanlı SCADA mimarileri, farklı marka ve modeldeki donanımların entegre çalışmasına olanak tanımaktadır (Şahin, Bolat ve Karaçor, 2012).

Bu protokoller, SCADA sistemlerinde kullanılan veri toplama üniteleriyle kontrol merkezi arasındaki iletişimi sağlamak için tercih edilen yöntemlerdir. Protokol seçimi, uygulama gereksinimlerine, kullanılan cihazlara ve diğer faktörlere bağlı olarak değişebilir.

SCADA sistemlerinin internet tabanlı protokollerle entegre edilmesi, kestirimci bakım verilerinin gerçek zamanlı ve güvenli şekilde iletilmesini mümkün kılmaktadır. Patel (2006), bu tür protokollerin SCADA ağlarında nasıl güvenli iletişim sağlayabileceğini analiz ederek, özellikle endüstriyel veri güvenliğinin bakım süreçlerindeki kritik rolüne dikkat çekmiştir.

Asubay (2018) tarafından hazırlanan yüksek lisans tezinde, SCADA sistemlerinde sıklıkla kullanılan haberleşme protokolleri (RS-232, RS-485, Modbus, Profibus) detaylı şekilde incelenmiş ve bu protokollerin sahadan merkeze veri iletim yapısı ile sistemin güvenilirliğine etkisi analiz edilmiştir.

4.3.3. Veri izleme ve kontrol merkezleri

SCADA yazılımı veya kontrol odası, verilerin toplandığı, izlendiği, analiz edildiği ve işlendiği merkezi bir yerdir. Operatörler, bu kontrol merkezi aracılığıyla süreçleri izleyebilir, ayarlamalar yapabilir ve gerekli önlemleri alabilir.


SCADA (Supervisory Control and Data Acquisition) sistemlerinde, kontrol merkezi, veri toplama birimleri tarafından toplanan ve işlenen verilerin izlendiği, analiz edildiği ve kontrol edildiği merkezi bir yerdir. Kontrol merkezi, operatörlere bir arayüz sağlayarak süreçlerin yönetilmesini ve kontrol edilmesini kolaylaştırır.

SCADA sistemlerinin merkezi bileşenleri HMI (Human Machine Interface - İnsan Makine Arayüzü) ekranları ve kontrol odalarıdır. Bu merkezlerde, toplanan veriler gerçek zamanlı izlenir ve gerektiğinde uzaktan müdahale edilir. Havacılıkta bakım operasyonları açısından bu merkezlerin etkin çalışması uçuş güvenliği açısından kritik öneme sahiptir.




Görsel 4.1. ESGAZ Merkez SCADA Odası

Veri izleme, kontrol merkezi, sahadan gelen verileri anlık olarak izler. Bu veriler sensörlerden, ölçüm cihazlarından veya diğer veri toplama birimlerinden toplanır. Kontrol merkezindeki kullanıcılar, veri ekranlarında süreç değerlerini, grafikleri, tabloları veya diğer görsel sunumları gözlemleyebilir. Böylece, süreçlerin anlık durumu hakkında bilgi sahibi olabilirler.



Görsel 4.2. ESGAZ SCADA ekranından örnek istasyon görseli

Veri analizi, SCADA kontrol merkezi, toplanan verileri analiz ederek operatörlere önemli bilgiler sunar. Bu analizler, süreç trendlerini, veri aralıklarını, hedeflerin karşılanıp karşılanmadığını veya alarm durumlarını içerebilir. Veri analizi, süreç performansının değerlendirilmesi, hataların veya anormalliklerin tespiti ve işletme verimliliğinin artırılması açısından kritik bir rol oynar.



Görsel 4.3. atvise® SCADA yazılımına ait arayüz görseli


SCADA kontrol merkezi, kullanıcı dostu bir arayüz sağlayarak operatörlerin süreçleri izlemesini, yönetmesini ve hızlı kararlar almasını kolaylaştırır. Ayrıca, veri kaydetme, raporlama, güvenlik ve erişim kontrolü gibi diğer özellikleri de içerebilir.

4.3.4. SCADA işletim sistemi

Bu bileşen diğer 5 bileşeni (Tag Editörü, Depolama, Alarm Birimi, Trend Birimi, Ekran Tasarım) denetleyen çekirdek yapıyı oluşturur. SCADA yazılımları, bir işletim sistemi (örneğin Windows veya Unix) üzerinde çalışan bir platform oluşturur. SCADA yazılım bileşenleri ise SCADA işletim yazılımı tarafından denetlenir. SCADA işletim sisteminin ana bileşenleri Şekil 4.6'da gösterilmiştir. SCADA işletim yazılımının temel görevleri:

- Bileşenler arası koordinasyon,

- Sistem tasarımcısı tarafından belirlenen mantıksal işlemleri gerçekleştirmektedir.



Şekil 4.6. SCADA işletim sisteminin birimleri

4.3.4.1. Sürücü ve etiket bağlantıları (Tag Editör)

Bu bileşen SCADA sunucusu ile dış dünya cihazları (PLC, RTU, Sensör ve Aktuatör) arasındaki bağlantıları sağlayabilecek olan iletişim protokolleri içerir. Bu yönüyle, şehrin etrafındaki su kaynaklarını şehre bağlayan sarnıçlara benzetilebilir. Aynı zamanda mantıksal denetim işlevlerini gerçekleştirmek amacıyla kullanılan iç bağlantı etiketleri de bu bileşenin görevidir.

4.3.4.2. Depolama

Bu birim adından da anlaşılacağı üzere SCADA sistemi tarafından denetlenen veya görüntülenen sistemle ilgili önemli bilgilerin depolandığı bölümdür.

4.3.4.3. Raporlama

Raporlama birimi, sahadan gelen çeşitli bilgiler istenildiğinde geriye dönük olarak SCADA sistemi üzerinden elde edilebilmesini sağlar. Bu birimde alınacak olan raporların tasarımı da yapılabilir.

4.3.4.4. Alarm birimi

Sistemde meydana gelebilecek arıza veya tehlike durumlarının tanımlanarak belirli alarm seviyelerinde sistem yetkililerine bildirilmesini sağlayan ayarların yapıldığı bölümdür. Alarm durumlarının mantıksal ayarları bu birimde gerçekleştirilmekle birlikte, alarm sayfalarının görsel tasarımları "Ekran Tasarımı" birimi tarafından hazırlanır.


Görsel 4.4’de örnek olarak bir SCADA sisteminde bulunan web ara yüzündeki alarm ekranı görseli görünmektedir. Bu ekranda alarmin ne zaman geldiği, ne zaman kapandığı, durumu, seviyesi, görülme zamanı vs. gibi tüm bilgiler bulunmaktadır. Her ne kadar bu görsel web arayüzüne ait olsa da, SCADA sistemlerinde genellikle izleme ekranlarında ayrı bir alarm ekranı da bulunur.

ID	Tip	Oluşma Tarihi	Kapanma Tarihi	Görülme Tarihi	Seviye	Lokasyon	Açıklama	Arz İşlem	Operator
418320	Alarm	29.03.2018 09:11:33			1	01_RM5A_HBU_MAMURDIYE	İstasyon A Hani Çıkış Basıncı - LL (13)		
418290	Alarm	29.03.2018 08:39:37			1	01_ML_HBU_30_TULOMAS	Yana-2 Arık - (1)		
418289	Alarm	29.03.2018 08:39:04			1	01_RM5A_HBU_ZINCIRLIKUYU	İstasyon Kalıyıcı - (3)		
418288	Alarm	29.03.2018 08:39:04			1	01_RM5A_HBU_ZINCIRLIKUYU	Oturum Hani-3 Basıncı - L (14.366264)		
418285	Alarm	29.03.2018 08:38:28			2	02_BR_HBU_B04R01	İstasyon Kapısı Açık - (1)		
418274	Alarm	28.03.2018 20:42:26			1	01_ML_HBU_KHD_ANKA_SERAMIK	Oturum Hani-1 Basıncı - L (16.349159)		
418197	Alarm	28.03.2018 13:51:36		28.03.2018 13:59:05	1	01_RM5A_HBU_ZINCIRLIKUYU	Regülatör-2 Arık - (1)		Sağcı HİKEM
418191	Alarm	28.03.2018 13:54:13		28.03.2018 13:59:05	1	01_RV_HBU_010003_V0_12	İstasyon Kapısı Açık - (1)		Sağcı HİKEM
418002	Alarm	28.03.2018 11:06:56		28.03.2018 11:18:14	1	01_RR_HBU_010001	Pano Kapısı Açık - (1)		Sağcı HİKEM
417983	Alarm	28.03.2018 02:57:18		28.03.2018 08:54:25	1	01_RR_HBU_010001	AC Enerji Arızası - (1)		Sağcı HİKEM

Görsel 4.4. ESGAZ SCADA web ara yüzü alarm ekranı


4.3.4.5. Trend birimi

Trende biriminde, sahadan alınan veriler operatöre yardımcı olmak için grafik üzerinde gösterilmektedir. Burada sahadan alınana geriye dönük belli aralıktaki verileriyle beraber anlık veriler gösterilmektedir. Bu sayede operatör verinin eğilimini ve değişimini daha kolay anlayabilmektedir.



Görsel 4.5. SCADA trend ara yüz görseli

Görsel 4.5 ve Görsel 4.6’da birbirine dolaylı yoldan bağlı olan iki verinin geçmişe dönük verileri trend ekranında gösterilmektedir.



Görsel 4.6. Örnek SCADA trend ekranı (ESGAZ SCADA trend ekranından alınmıştır.)

4.3.4.6. Ekran tasarımı

Bu bölümde operatörler tarafından izlenecek ekranlar tasarlanır. İzlenecek ekranın tasarımı, renklendirilmesi, alınacak verilerin düzenlenmesi ve sahadan gelecek verilerde ekranda ne gibi değişiklikler (renk, uyarı vb.) olması gerektiği gibi tüm işlemler bu birim üzerinde yapılır.

4.4. SCADA Sistemlerinin Havacılıkta Kullanım Alanları

SCADA sistemleri aşağıda bahsedilen hava trafik kontrolleri, havaalanı operasyonları, uçak bakımı ve uçak gövde yapı izleme gibi alanlarda kullanılmaktadır. Genel olarak havacılık bakım süreçlerinde ise aşağıdaki alanlarda kullanılmaktadır.

- Motor performans izleme: Motorların çalışma sırasında oluşturduğu titreşim, sıcaklık ve basınç verileri SCADA ile sürekli takip edilir.
- Hidrolik sistemlerin takibi: Uçuş kontrol yüzeylerini hareket ettiren hidrolik sistemlerin basınç ve sızıntı durumları kontrol edilir.
- Elektrik ve aviyonik sistemlerin denetimi: Elektrik kabloları, batarya sistemleri ve elektronik modüller SCADA sistemine bağlanarak anlık kontrol edilir.
- Zemin destek sistemlerinin entegrasyonu: Hangar içindeki enerji sistemleri, klima kontrol sistemleri, hidrolik test ekipmanları SCADA ile entegre çalışabilir.
- Yedek parça ve depo yönetimi: Modern SCADA sistemleri, envanter kontrol modülleriyle yedek parça stoklarını da yönetebilir.

4.4.1. Hava trafik kontrolü

SCADA sistemleri, hava trafik kontrol merkezlerinde kullanılarak hava trafik yönetimini destekler. Hava trafik kontrolörleri, radar verilerini, uçuş planlarını, hava durumu bilgilerini ve diğer önemli verileri SCADA sistemleri aracılığıyla izleyebilir ve yönetebilir. Bu sistemler, hava trafik yoğunluğunu izlemek, uçakların güvenli bir şekilde uçmalarını sağlamak ve havaalanı trafiğini düzenlemek için kullanılır.

Hava trafik kontrolü, SCADA (Supervisory Control and Data Acquisition) sistemleriyle desteklenen karmaşık bir süreçtir. SCADA sistemleri, hava trafik kontrol merkezlerinde kullanılarak hava trafik yönetimini etkinleştirmek için önemli bir rol oynar.

SCADA sistemleri, hava trafik kontrol merkezlerindeki radar verilerini, uçuş planlarını, hava durumu bilgilerini ve diğer önemli verileri toplayarak gerçek zamanlı izleme ve kontrol imkanı sağlar. Bu sistemler, hava trafik kontrolörlerine hava sahasını, uçuş rotalarını ve uçak trafiğini izleme yeteneği sunar. Operatörler, bir kontrol paneli veya görsel ekran aracılığıyla hava trafiğini gözlemleyebilir, uçuşları izleyebilir ve gerektiğinde yönlendirmeler yapabilir.


SCADA sistemleri aynı zamanda hava trafik kontrolünde veri analizi ve raporlama için kullanılır. Uçuş verileri, hava trafik yoğunluğu, ortalama hız, yakıt tüketimi ve diğer parametreler SCADA sistemleri tarafından kaydedilir ve analiz edilir. Bu analizler, hava trafik kontrol merkezlerinin uçuş planlamasını, hava sahası yönetimini ve diğer stratejik kararları destekler.

Hava trafik kontrolünde SCADA sistemleri, uçakların güvenli bir şekilde seyahat etmelerini sağlamak, hava trafiğini düzenlemek, rotalarda verimliliği artırmak ve kritik durumlarda hızlı yanıt vermek için kullanılır. Operatörler, SCADA sistemleri aracılığıyla uçuşları izleyebilir, uçaklara talimatlar verebilir ve anlık durumları kontrol edebilir.

Ancak, hava trafik kontrolü daha karmaşık bir süreçtir ve SCADA sistemleri yalnızca bir bileşenidir. Diğer sistemler, örneğin hava trafik kontrol radarları, haberleşme sistemleri ve uçuş planlama yazılımları da hava trafik kontrolünün tamamlayıcı unsurlarını oluşturur. Bu sistemler bir arada çalışarak güvenli, verimli ve düzenli bir hava trafiği sağlamayı hedefler.

4.4.2. Havaalanı operasyonları

SCADA sistemleri, havaalanlarında altyapı sistemlerini kontrol etmek ve izlemek için kullanılır. Pist aydınlatması, rüzgar ölçümü, yangın güvenliği, enerji dağıtımı, su ve kanalizasyon yönetimi gibi sistemler, SCADA sistemleri aracılığıyla merkezi bir konumdan kontrol edilebilir. Bu sistemler, havaalanı operatörlerine sistemlerin durumunu izleme, alarm oluşturma ve uzaktan kontrol etme imkanı sağlar. Görsel 4.7’de bir havaalanının aydınlatma sistemini izleyen SCADA ekranı görülmektedir.



Görsel 4.7. *Isparta Kara Havacılık Okulu havaalanı aydınlatma SCADA sistemi (CEDETAŞ)*


4.4.3. Uçak bakımı

SCADA sistemleri, uçak bakım ve onarım süreçlerinde de kullanılır. Uçaklardan alınan sensör verileri, SCADA sistemleri aracılığıyla toplanır ve analiz edilir. Bu veriler, uçakların durumu, motor performansı, yakıt tüketimi, sıcaklık, basınç gibi önemli parametreleri içerebilir. Bakım ekipleri, SCADA sistemleri sayesinde uçakların durumunu izleyebilir, bakım ihtiyaçlarını belirleyebilir ve gerekli önlemleri alabilir.

4.4.4. Uçak gövde ve yapı izleme


SCADA sistemleri, uçak gövdesi ve yapısal bileşenlerin izlenmesi için kullanılabilir. Bu sistemler, uçakların titreşim, gerilme, yük ve deformasyon gibi yapısal parametrelerini izler ve olası sorunları tespit eder. Bu sayede uçakların güvenliği ve bakım süreçleri optimize edilir.

Bu uygulamalar, havacılık endüstrisinde SCADA sistemlerinin kullanıldığı ancak sınırlı olmayan alanlardan sadece birkaç örnektir. Havacılıkta SCADA sistemleri, operasyonel veri toplama, kontrol, izleme ve güvenlik açısından önemli bir rol oynamaktadır.



Şekil 4.7. Uçaklar için kullanılacak örnek SCADA mimarisi


Şekil 4.7 incelendiğinde, uçak üzerindeki dijital ve analog sinyallerin RTU (Remote Terminal Unit) aracılığıyla toplandığı ve bu verilerin kokpitte bulunan SCADA sistemine aktarıldığı görülmektedir.



Şekil 4.8. Uçak üzerinden okunan verilerin değişiminde SCADA sistemine gönderilen örnek veriler

Şekil 4.8'e bakıldığında analog veri değişim aralığına göre bir sinyal değişimi olduğunda RTU üzerindeki veriler modem aracılığıyla merkezde bulunan SCADA sistemine gönderilmektedir. Bu yöntemle uçakla ilgili kritik tüm veriler merkezden izlenebilir. Uzaktan herhangi bir acil durumda istenirse uçak kontrolü yapılabilir. Şekil 4.8'de veri değişimi olduğunda merkez SCADA sistemine veri gönderildiği anlatılmaya

Görsel 4.8’de örnek olarak bir uçağın kokpitinde bulunan SCADA izleme ekranı görülmektedir. Bu ekranların tasarımı tamamen SCADA sistemini kullanan kullanıcıların istekleri ve SCADA sisteminin kontrol ettiği prosesin gereksinimine bağlıdır. İstenirse genel bir ekran tasarlanıp, genel ekrandan (dashboard vb.) önemli sinyaller de izlenebilir.



55

4.5. SCADA Sistemlerinin Havacılıkta Sağladığı Avantajlar

SCADA sistemleri, havacılık sektöründe özellikle uçak bakım faaliyetleri, havaalanı yer hizmetleri ve yakıt yönetimi gibi alanlarda yaygın olarak kullanılmaktadır. Bu sistemlerin sağladığı başlıca avantajlar şu şekilde sıralanabilir:

Gerçek zamanlı takip: Uçak bakım süreçlerinin tüm adımları anlık olarak izlenebilir.

Arıza öncesi müdahale: Sensörlerden gelen veriler analiz edilerek önleyici bakım algoritmaları devreye alınabilir.

İşgücü ve maliyet tasarrufu: Gereksiz bakım işlemleri azaltılarak bakım süreleri ve personel maliyetleri düşürülür.

Veriye dayalı karar verme: Uçuş öncesi ve sonrası bakım kararları daha nesnel ve güvenilir şekilde alınır.

Entegre raporlama: SCADA sistemleri bakım performansını raporlar, kalite yönetim sistemleriyle uyum sağlar.

4.6. Havacılıkta SCADA Uygulamalarına Yönelik Zorluklar

SCADA sistemlerinin havacılıkta kullanımı, yüksek düzeyde güvenlik gereklilikleri ve düzenleyici gereksinimlerle karşı karşıyadır. Bu sistemlerin havacılık standartlarına uygun olarak tasarlanması ve güvenlik açıklarının minimum düzeyde tutulması gerekmektedir. Özellikle veri güvenliği, siber tehditlere karşı koruma ve uluslararası havacılık otoritelerinin belirlediği standartlara (ICAO, EASA, FAA) uyum sağlamak, bu alandaki başlıca zorluklar arasında yer alır. Bu nedenle, havacılıkta SCADA uygulamalarının geliştirilmesi ve yönetimi, ileri düzey mühendislik çözümleri ve detaylı planlama süreçleri gerektirmektedir. Aşağıda karşılaşılan başlıca zorluklar şu şekilde özetlenebilir.

Siber güvenlik: Havacılık sektörü için kritik olan veri gizliliği ve bütünlüğü, SCADA sistemlerinin önemli güvenlik açıkları arasında yer almaktadır. Yadav ve Paul (2021), SCADA sistemlerinin modüler mimarisini ve bu sistemlerin siber tehditlere karşı savunmasız noktalarını kapsamlı bir şekilde incelemiş; özellikle enerji, su ve ulaştırma gibi kritik altyapılarda güvenliğin artırılmasına yönelik mimari öneriler sunmuştur.

Donanım ve entegrasyon maliyeti: Uçaklara ya da bakım tesislerine yeni sensör ve modüller eklemek ciddi yatırım gerektirir.

Standartlaşma sorunu: Farklı üreticilerin SCADA çözümleri arasında uyumluluk eksikliği olabilir.

Eğitim ve yetkinlik eksikliği: SCADA sistemlerinin etkin kullanımı için teknik personelin özelleşmiş eğitimler alması gerekir.

4.7. Havacılıkta Dijitalleşme Süreci ve SCADA'nın Rolü

Günümüzde havacılık sektöründe sadece uçakların değil, aynı zamanda bakım süreçlerinin de dijitalleştiği bir dönüşüm gerçekleşmektedir. Bakım faaliyetlerinin manuel ve kağıt temelli sistemlerden uzaklaşarak, veri odaklı ve otomatik süreçlerle yönetilmesi hem emniyet hem de operasyonel verimlilik açısından önem arz etmektedir. Bu dönüşüm, sadece teknolojik cihazların entegrasyonu ile sınırlı kalmayıp, aynı zamanda kurumsal iş süreçlerinin dijital altyapılarla yeniden tasarlanmasını da içermektedir.

SCADA sistemleri, bu dönüşüm sürecinde kritik rol oynayan platformlardır. Uçak bakım operasyonlarında yer alan yüzlerce farklı bileşenin durumunu gerçek zamanlı izlemek, veri tabanlarında saklamak ve analiz etmek için kullanılmaktadır. Ayrıca, bakım yönetim sistemleri (CMMS - Computerized Maintenance Management Systems) ile entegre çalışarak bakım emirlerinin dijital ortamda oluşturulmasını, takip edilmesini ve raporlanmasını sağlamaktadır.

Özellikle büyük hava yollarında, bakım planlama süreçleri artık sadece teknik veriye değil, yapay zekâ destekli kestirimci algoritmalara da dayanmaktadır. Uçak bileşenlerinden elde edilen sensör verileri SCADA sistemine iletilmekte, bu veriler doğrultusunda hangi bileşenin ne zaman arızalanabileceği tahmin edilmekte ve buna göre bakım planı çıkarılmaktadır. Bu durum hem arızaya dayalı bakımın azaltılmasını sağlamakta hem de insan kaynaklarının daha etkin kullanılmasına olanak tanımaktadır.

Ayrıca dijital dönüşüm, bakım kayıtlarının elektronik ortamda arşivlenmesini, uzaktan denetlenmesini ve düzenleyici otoritelerle paylaşılmasını da kolaylaştırmaktadır. EASA Part-M ve Part-145 gibi düzenlemeler, dijital bakım kayıtlarının kabul edilebilir formatlarda saklanmasını teşvik etmektedir.

Sonuç olarak, havacılıkta bakım yönetiminin dijital dönüşümü; yalnızca teknolojik bir ilerleme değil, aynı zamanda stratejik bir zorunluluk hâline gelmiştir. SCADA sistemlerinin bu süreçteki yeri, sadece veri izleme değil; aynı zamanda karar destek, otomasyon ve güvenlik yönetimi açısından da hayati önem taşımaktadır.

4.8. Gelecek Perspektifi ve Entegrasyon Potansiyeli

SCADA sistemleri artık yalnızca izleme aracı olmaktan çıkıp, karar destek sistemlerine dönüşmektedir. Özellikle:

- Yapay zekâ ile desteklenen SCADA sistemleri, arıza nedenlerini otomatik olarak teşhis edebilir.
- Uçak içi bileşenler de sürekli izlenebilir hale gelmektedir.
- Dijital ikiz teknolojisi ile uçakların birebir dijital kopyaları üzerinden simülasyonlar yapılabilir.

Tüm bu gelişmeler, SCADA sistemlerini, uçuş güvenliği, maliyet planlaması ve filo yönetimi gibi daha stratejik alanlara taşımaktadır.

Sonuç olarak SCADA sistemleri, havacılıkta dijital dönüşümün temel taşı hâline gelmiştir. Stratejik olarak entegre edildiğinde, bu sistemler yalnızca bakım süreçlerini değil, uçuş güvenliğini ve şirketlerin rekabet gücünü doğrudan etkilemektedir.

5. ANALİZ VE BULGULAR

Bu bölümde, uçak bakım süreçlerinde kestirimci bakım stratejilerinin uygulanabilirliğini incelemek amacıyla geliştirilen yapay zeka temelli analiz süreci ayrıntılı olarak ele alınmıştır. Süreç, sentetik veri üretiminden başlayarak etiketleme, ön işleme ve farklı algoritmaların uygulanmasına kadar tüm adımları kapsamaktadır. Çalışmada, gerçek verinin bulunmaması nedeniyle sıcaklık, titreşim ve fan hızı gibi sensör değişkenlerine dayalı kontrollü bir veri seti oluşturulmuş ve bu veriler üzerinde kestirimci modeller geliştirilmiştir. Destek Vektör Makineleri (SVM), Karar Ağaçları (DT), Yapay Sinir Ağları (ANN) ve Uzun Kısa Süreli Bellek (LSTM) gibi algoritmalar ile yapılan analizlerin doğruluk, hata oranı ve karar süresi gibi metriklere göre karşılaştırmalı değerlendirmesi gerçekleştirilmiştir.


Bu bölümde ayrıca, algoritmaların etkin şekilde eğitilebilmesi için sentetik veri üretimi gerçekleştirilmiştir. Sırasıyla Destek Vektör Makineleri (SVM), Karar Ağaçları (DT), Yapay Sinir Ağları (ANN) ve Uzun Kısa Süreli Bellek (LSTM) algoritmaları, aynı veri seti üzerinde değerlendirilmiştir. Literatürde basit algoritmalar için 500–1000 veri yeterli görülse de, zaman serisi temelli LSTM gibi modellerin sağlıklı eğitimi için 2000–5000 kayıt arası veri önerilmektedir. Bu bağlamda çalışmada 3000 saatlik sentetik veri kullanılmıştır. Ayrıca, oluşturulan arıza skorlarının sensör değişkenleriyle olan ilişkisinin makul düzeyde olmasını sağlamak amacıyla regresyon kontrolü uygulanmış; böylece veri üretim sürecinin analitik ve tutarlı olması hedeflenmiştir.

Turbofan motorlarında uzun-kısa süreli bellek yapılarıyla yapılan kestirimci analizlerin, motor performansına ilişkin zamansal örüntüleri doğru şekilde modellediği gösterilmiştir (Volkan ve Inner, t.y.).


5.1. Veri Seti Oluşturulması

Kestirimci bakım analizlerinin gerçekleştirilebilmesi için sentetik bir veri seti oluşturulmuştur. Gerçek uçak motoru sistemlerinde kullanılan sensör parametrelerinin aralıkları, teknik dokümanlar ve akademik yayınlar temel alınarak belirlenmiştir. Oluşturulan veri seti, ilerleyen bölümlerde uygulanacak kestirimci modellerin eğitimi ve testi için temel teşkil etmektedir. Her bir satır bir saatlik izlemeyi yansıtmaktadır.


Oluşturulan sensör verilerinin zaman içindeki davranışları aşağıda grafiksel olarak Şekil 5.1, Şekil 5.2 ve Şekil 5.3'te sunulmuştur.



Şekil 5.1. Sıcaklık değişimi zaman serisi



Şekil 5.2. Titreşim değişim zaman serisi



Şekil 5.3. Fan hızı değişimi zaman serisi

Aşağıdaki Şekil 5.4'te, sentetik veri üretiminden analiz sürecine kadar izlenen adımlar akış diyagramı ile sunulmuştur. Bu diyagram, değişkenlerin seçimi, veri üretimi, arıza skoru oluşturulması ve regresyon kontrolü gibi temel adımları kapsamaktadır.



Şekil 5.4. Veri seti üretim ve hazırlık süreci akış diyagramı

5.1.1. Seçilen değişkenler

Veri setinde motorun termal ve mekanik sağlığını yansıtan üç temel parametre yer almaktadır:

Sıcaklık (°C): Motor içi sıcaklık, rulman sıcaklığı ve yanma verimliliği gibi unsurların göstergesidir.

Titreşim (mm/s): Rotor dengesizliği, gevşeklik ve mekanik aşınmaların tespitinde kullanılır.

Fan Hızı (%Fn): Motorun yük ve performans karakteristiğini temsil eder. Bu parametreler, uçak motorlarında kestirimci bakım çalışmalarında en yaygın kullanılan değişkenler arasında yer almakta olup, özellikle sıcaklık, titreşim ve fan hızı gibi sensör verileri; motor performansının izlenmesi, arıza öncesi davranışların tespiti ve güvenliğin artırılması amacıyla birçok çalışmada temel giriş değişkeni olarak tercih edilmiştir (Zonta ve diğerleri, 2020; Yıldırım ve Rana, 2024; Incose ve diğerleri, 2024).

Çalışmaya dahil edilmesi düşünülen ancak doğrudan motor arızaları ile ilişkisi zayıf olan hidrolik basınç gibi değişkenler ise model dışı bırakılmıştır.

5.1.2. Değişkenlerin seçim gerekçesi ve literatür dayanakları

Aşağıdaki tabloda kullanılan her bir değişkenin gözlemlenebilir aralıkları, arıza ile ilişkilendirilme nedenleri ve bu ilişkinin akademik literatürdeki yeri Tablo 5.1’de sunulmuştur.

Tablo 5.1. Değişkenlerin aralığı, gerekçesi ve literatör dayanakları

Değişken	Genel Aralık	Arıza Belirteci Olma Nedeni	Literatürde Arıza ile İlişkilendirilme Sıklığı	Akademik Kaynak Örneği
Sıcaklık (°C)	180 - 260	Rulman aşırı ısınması, yanma odası verimsizlikleri	Yüksek – birçok kaynakta yer alır	Li ve diğerleri, 2020
Titreşim (mm/s)	1.0 - 5.0	Rotor dengesizliği, gevşeklik, eksenel kaçıklık	Çok yüksek – ana parametrelerden biri	Saxena ve diğerleri, 2008 (NASA C-MAPSS); Randall ve Antoni, 2011
Fan Hızı (%)	75 - 95	Rotor sürtünmesi, yanma bozukluğu, yük dengesizliği	Orta – destekleyici bir gösterge olarak kullanılır	Gao ve diğerleri, 2021

Dengesiz veri setiyle başa çıkmak için yapılan değişken sınırlamaları, özellikle arıza sıklığının az olduğu havacılık uygulamalarında önerilmektedir (He ve Garcia, 2009).

5.1.3. Arıza skoru hesaplaması

Her bir kayıt için bir arıza skoru hesaplanmıştır. Bu skor, ilgili değişkenlerin lineer kombinasyonu şeklinde tanımlanmıştır. Veriler simülasyon ortamında üretildiğinden, hangi örneklerin arızalı durumları temsil ettiğine dair önceden tanımlı etiketler bulunmamaktadır. Bu nedenle, arıza durumlarını belirlemek amacıyla veriler üzerinden bir arıza skoru hesaplanması gerekliliği ortaya çıkmıştır. Bu nedenle değişkenlerin etkisine göre bir arıza skoru oluşturulup bazı kayıtlar bu skora göre arızalı diye

işaretlenecektir. Bu veriler ilerleyen bölümlerde anlatılacak yapay zeka yöntemlerini eğitmekte kullanılacak ve bu veriler ile analiz gerçekleştirilecektir.

Bu çalışmada iki aşamalı normalizasyon yaklaşımı uygulanmıştır. İlk aşamada, sentetik veri üretimi sırasında sıcaklık, titreşim ve fan hızı değişkenleri, [0–1] aralığına normalize edilmiştir. Bu sayede değişkenlerin etkisi tek bir skala üzerine indirgenmiş ve ağırlıklandırma süreciyle birlikte sentetik arıza skoru hesaplaması gerçekleştirilmiştir.


$$\text{Arıza Skoru} = a \times \text{Sıcaklık} + b \times \text{Titreşim} + c \times \text{Fan Hızı} + \varepsilon \quad (5.1)$$

Burada katsayılar aşağıdaki gibidir:

- $a = 0.0278$
- $b = 1.4662$
- $c = 0.0217$
- ε : Ortalaması 0, standart sapması 0.5 olan normal dağılımlı gürültü

Bu çalışmada kullanılan arıza skoru, gerçek etiketli veriler mevcut olmadığından dolayı sentetik olarak oluşturulmuştur. Ancak tamamen rastlantısal şekilde değil, kontrollü bir yapı ile elde edilmiş ve regresyon analizi ile tersine çözümleme uygulanarak sensör değişkenlerinin arıza skoruna etkileri doğrulanmıştır. Veri üretim sürecinde, sıcaklık, titreşim ve fan hızı değişkenleri normalize edilmiş, ağırlıklı şekilde birleştirilmiş ve gürültü eklenmiştir. Daha sonra elde edilen skorlar, regresyonla yeniden analiz edilerek kullanılan katsayıların skor üzerindeki etkisi doğrulanmıştır.

Oluşturulan arıza skorunun zaman içindeki davranışları aşağıda grafiksel olarak Şekil 5.5’te sunulmuştur.



Şekil 5.5. Oluşturulan arıza skorunun değişimi zaman serisi

İkinci aşamada ise, oluşturulan veri seti üzerinde yapay zeka modellerinin eğitimi öncesinde “**StandardScaler**” yöntemi ile tekrar standartlaştırılmıştır. Bu yöntemde her bir değişkenin ortalaması sıfıra, standart sapması bir e getirilmiştir. Bu tür standartlaştırma, özellikle destek vektör makineleri (SVM), yapay sinir ağları (ANN) ve LSTM gibi algoritmalarda öğrenme sürecinin dengeli olmasını sağlar.

5.1.4. Arıza etiketi atama yöntemi

Arıza skorlarına göre tüm kayıtlar yüksekte düşüğe sıralanmış, en yüksek 300 kayıt (ilk %10) "Arıza = 1" olarak etiketlenmiştir. Geri kalan 2700 kayıt ise "Arıza = 0" olarak bırakılmıştır. Bu yaklaşım, dengesiz veri seti üzerinde yapay zeka modellerinin eğitilmesine yönelik literatür destekli bir stratejidir. Dengesiz veri setleriyle çalışmalarda bu tür oranlı etiketleme stratejisi önerilmektedir. Etiketleme stratejisi, anomali oranına göre belirlenen eşik değeri yaklaşımını benimser (Malhotra ve diğerleri, 2015).

Bu işlemler sonucunda, toplamda 3000 kayıtlık veri için hem sayısal skor hem de ikili etiket bilgisi oluşturulmuştur. Aşağıda oluşturulan 3000 kayıtlık verinin ilk 30 kaydı Şekil 5.6’da gösterilmiştir.

Kayıt	Sıcaklık (°C)	Titreşim (mm/s)	Fan Hızı (%Fn)	Arıza Skoru	Yeni Arıza Etiketi
1	229,934283	0,973753954	79,4295932	9,926214367	0
2	217,234714	1,811691991	81,8453458	11,0081782	0
3	232,953771	2,169115573	80,2896991	11,64810351	0
4	250,460597	4,010150126	82,2600209	13,65628032	1
5	215,316933	2,9452425	83,9292484	12,04767875	0
6	215,317261	1,431614745	89,1857724	9,442330865	0
7	251,584256	2,888829032	83,3942048	12,93799481	0
8	235,348695	1,262156809	77,0718715	10,55572975	0
9	210,610512	3,366152843	90,7003392	12,91119832	0
10	230,851201	2,123100279	80,8145493	11,85827417	0
11	210,731646	2,425091049	84,7063979	11,42301405	0
12	210,685405	3,560637318	87,2326825	12,32144693	0
13	224,839245	1,470269145	85,9980521	9,011973871	0
14	181,734395	1,382305452	90,4708977	9,116575299	0
15	185,501643	2,033120539	87,3950157	9,927415627	0
16	208,754249	3,330703081	80,6934521	11,94942003	0
17	199,743378	1,28452314	95,8928109	8,666794095	0
18	226,284947	0,234275522	85,9716673	8,132429861	0
19	201,839518	2,139072913	84,2632989	10,47871516	0
20	191,753926	2,94139264	89,8196271	11,92545385	0
21	249,312975	3,4602094	86,2472547	13,97014071	1
22	215,484474	2,12947091	86,996141	11,80454851	0
23	221,350564	2,170858714	97,46092	10,93355866	0
24	191,505036	3,423120587	83,6243929	12,59799818	0
25	209,112346	1,00420664	83,4111955	9,119363296	0
26	222,218452	2,18918338	85,5828926	11,59193696	0
27	196,980128	2,652339112	90,3575797	11,10740922	0
28	227,51396	2,859374977	77,4673298	12,73418493	0
29	207,987226	2,092154645	75,1722205	10,62841159	0
30	214,166125	2,527552809	82,0644236	11,1007917	0

Şekil 5.6. Oluşturulan 3000 kayıtlık verinin ilk 30 kaydı

5.2. Yapay Zeka Algoritmaları ile Arıza Tahmini

Uçak motorları gibi karmaşık sistemlerde, bakım süreçlerinin optimize edilmesi ve beklenmedik arızaların önüne geçilebilmesi için kestirimci bakım stratejilerinin uygulanması kritik öneme sahiptir. Bu bağlamda, makine öğrenimi ve yapay zeka tabanlı sınıflandırma algoritmaları, arızaların önceden tespit edilebilmesi için güçlü araçlar

sunmaktadır. Bu çalışmada, oluşturulan sentetik veri seti üzerinde çeşitli yapay zeka algoritmaları kullanılarak arıza tahmini yapılmıştır.

Her bir algoritma (SVM, Karar Ağaçları, ANN, LSTM) aynı veri seti üzerinde eğitilmiş ve test edilmiştir. Modellerin performansları doğruluk (accuracy), F1-score, ROC eğrisi (AUC) ve karışıklık matrisi (confusion matrix) gibi metriklerle değerlendirilmiştir. Bu analizler ile farklı algoritmaların kestirimci bakım sistemlerinde ne ölçüde etkili olduğu karşılaştırmalı olarak ortaya konulmuştur. Elde edilen bulgular, veri özelliklerine göre algoritma seçiminde dikkat edilmesi gereken hususlara da ışık tutmaktadır.

Yapılan analizlerde kullanılan temel performans ölçütleri aşağıda tanımlanmıştır:

Accuracy (Doğruluk): Modelin test verileri üzerindeki genel doğruluk oranıdır.

F1-Skoru: Precision (kesinlik) ve Recall (duyarlılık) değerlerinin harmonik ortalamasıdır. Özellikle dengesiz veri setlerinde önemlidir.

ROC Eğrisi (Receiver Operating Characteristic): Modelin farklı eşik değerlerinde ne kadar ayırt edici olduğunu gösteren eğridir.

AUC (Area Under Curve): ROC eğrisinin altında kalan alandır. Değer 1'e ne kadar yakınsa modelin ayırıştırma gücü o kadar yüksektir.

Confusion Matrix (Karışıklık Matrisi): Gerçek ve tahmin edilen sınıfların karşılaştırıldığı bir matristir.

Model eğitimi öncesinde, sensör değişkenleri “StandardScaler” kullanılarak normalize edilmiştir. Bu sayede her değişkenin etkisi aynı ölçeğe indirgenmiş ve algoritmaların daha dengeli öğrenmesi sağlanmıştır.

Python programlama dili, veri analitiği ve teknik uygulamalar açısından güçlü bir araç olarak kabul edilmekte, kestirimci bakım uygulamalarında veri işleme ve modelleme süreçlerinde etkin şekilde kullanılmaktadır (Nagpal ve Gabrani, 2019).

Python dili, açık kaynaklı yapısı ve geniş kütüphane desteğiyle makine öğrenimi uygulamalarında yaygın olarak kullanılmaktadır. Raschka ve diğerleri (2020), Python'un veri bilimi ve yapay zeka alanındaki gelişimini sistematik olarak inceleyerek bu dilin güncel teknolojik eğilimlerdeki rolünü ortaya koymuştur.

Yapay zekâ algoritmalarının Python programlama dili aracılığıyla uygulanması, kestirimci bakım sistemlerinin hızlı prototipleme ve test süreçlerini kolaylaştırmaktadır. Teoh ve Rong (2022), Python tabanlı yapay zekâ geliştirme süreçlerine ilişkin olarak

SVM, yapay sinir ağıları ve derin öğrenme gibi modellerin yapılandırılmasını ayrıntılı biçimde açıklamaktadır.

Yapay zeka algoritmalarının Python dili ile uygulanması, kestirimci bakım gibi veri odaklı süreçlerde yaygın hale gelmiştir. Joshi (2017), Python ile sinir ağıları, karar ağaçları ve SVM gibi algoritmaların gerçek veri setleriyle nasıl eğitilip test edileceğini adım adım açıklayarak bu alanda uygulama odaklı önemli bir kaynak sunmaktadır.

Zaman serisi verilerinin tahmini ve ileriye dönük analizleri, kestirimci bakım sistemlerinin başarısında belirleyici rol oynamaktadır. Sideratos ve Hatziaargyriou (2007), rüzgar gücü tahmini amacıyla geliştirdikleri istatistiksel yaklaşım ile, değişken verilerin öngörülebilirliğini artırmanın operasyonel karar süreçlerine katkısını göstermiştir.

Zaman serisi modellerine dayalı arıza zamanı tahmini, kestirimci bakım planlamasında önemli avantajlar sunmakta olup, bu yaklaşımla yapılan akademik çalışmalar arıza öncesi müdahale imkânlarını artırmaktadır (Kaynak, 2022).

5.2.1. Destek vektör makineleri (SVM) ile arıza tahmini

Destek Vektör Makineleri (SVM), doğrusal ve doğrusal olmayan sınıflandırma problemlerinde sıkça kullanılan güçlü bir denetimli öğrenme algoritmasıdır. Bu çalışmada, oluşturulan sentetik veri seti üzerinde arıza tespiti için SVM algoritması uygulanmıştır. Modelin eğitimi ve testi için veri seti %70 (2100 kayıt) eğitim ve %30 (900 kayıt) test olarak ayrılmıştır. Model, sıcaklık, titreşim ve fan hızı parametrelerini kullanarak arıza olup olmadığını tahmin etmektedir. Tüm sensör değişkenleri normalize edilerek analiz gerçekleştirilmiştir. Python programlama dili ve scikit-learn kütüphanesi kullanılarak gerçekleştirilmiştir. SVM analizinin başarımlı sonucu Tablo 5.2’de özetlenmiştir.

Tablo 5.2. SVM analizi test verisindeki başarımlı sonucu

Ölçüt	Değer
Doğruluk (Accuracy)	%96.3
F1 Skoru	0.79
AUC (ROC Eğrisi Altındaki Alan)	0.965

Doğruluk (Accuracy): SVM algoritması ile gerçekleştirilen sınıflandırma sonucunda doğruluk oranı %96.3 olarak elde edilmiştir. Doğruluk, modelin tüm tahminleri içerisindeki doğru sınıflandırma oranını ifade eder. Yani 900 test örneğinin %96.3’ü doğru bir şekilde tahmin edilmiştir.

Ancak, doğruluk tek başına performansı değerlendirmek için yeterli değildir, özellikle de sınıf dağılımının dengesiz olduğu durumlarda yanıltıcı olabilir. Çünkü doğruluk, nadir görülen sınıflarda (örneğin arıza sınıfı gibi) düşük performansı maskeleyebilir. Bu nedenle, modelin başarısını daha iyi yansıtabilmek adına precision, recall ve F1-score gibi ek metriklerin değerlendirilmesi gereklidir (Saito ve Rehmsmeier, 2015).


F1 Skoru: Bu analizde F1 skoru 0.79 olarak hesaplanmıştır. F1 skoru, precision (kesinlik) ve recall (duyarlılık) değerlerinin harmonik ortalaması olup, özellikle dengesiz veri setlerinde daha güvenilir bir performans göstergesidir.

F1 skoru, modelin arızalı (pozitif) sınıfı ne kadar doğru ve eksiksiz yakalayabildiğini ifade eder. Bu çalışmadaki 0.79 değeri, modelin arızalı örnekleri yeterli düzeyde tanımladığını ve sınıflar arası ayrımı makul seviyede gerçekleştirdiğini göstermektedir.

Özellikle yanlış negatiflerin azaltılması gereken kestirimci bakım senaryolarında, F1 skoru sistem güvenliği ve bakım planlaması açısından kritik öneme sahiptir (Lipton ve diğerleri, 2014).

Karışıklık Matrisi (Confusion Matrix): Karışıklık matrisi modeli dört kategoriye ayırır: doğru negatif (TN), yanlış pozitif (FP), yanlış negatif (FN), doğru pozitif (TP). Bu çalışmada Şekil 5.6'da görüldüğü üzere $TN = 804$, $FP = 6$, $FN = 27$ ve $TP = 63$ olarak hesaplanmıştır. Bu sonuçlar, modelin özellikle arızasız kayıtları doğru tespit etmede oldukça başarılı olduğunu, ancak özellikle yanlış negatif ($FN = 27$) değerinin varlığı, modelin bazı arızalı kayıtları “arıza yok” olarak değerlendirdiğini göstermektedir. Bu durum, kestirimci bakım uygulamalarında kritik öneme sahiptir; çünkü gözden kaçan arızalar bakım maliyetlerini artırabilir ve sistem güvenliğini tehlikeye atabilir. Bu nedenle modelin duyarlılığı (recall) gibi ölçütleri, sadece doğruluk oranı kadar değil, hatta bazı senaryolarda daha da fazla önem taşır.


Ayrıca yanlış pozitif sayısının düşük ($FP = 6$) olması, sistemin gereksiz bakım alarmı üretmediğini ve bu nedenle bakım operasyonlarında verimliliği artırabileceğini ortaya koymaktadır. Bu bağlamda, SVM modelinin sınıflandırma performansı dengeli bir yapı sergilemiş ve özellikle sağlam kayıtları tespit etmede yüksek başarı sağlamıştır.



Şekil 5.7. SVM analizi karışıklık matrisi

ROC Eğrisi ve AUC: Modelin ROC (Receiver Operating Characteristic) eğrisi üzerinde yapılan değerlendirmede, AUC (Area Under the Curve) değeri 0.965 olarak elde edilmiştir. ROC eğrisi, farklı eşik değerleri altında modelin duyarlılığı (true positive rate) ve yanlış alarm oranını (false positive rate) karşılaştırarak sınıflar arasındaki ayırım yeteneğini görselleştirir.

AUC değeri 1'e yaklaştıkça, modelin pozitif ve negatif sınıfları ayırt etme kabiliyeti artar. Bu bağlamda 0.965 gibi yüksek bir AUC, SVM algoritmasının güçlü bir sınıflandırma yeteneğine sahip olduğunu ve erken teşhis veya bakım kararı gibi kritik karar destek süreçlerinde güvenle kullanılabileceğini ortaya koymaktadır (Fawcett, 2006).



Şekil 5.8. SVM analizi ROC eğrisi

Modelin sınıflandırma performansı genel olarak değerlendirildiğinde; doğruluk (accuracy), F1-score, ROC eğrisi ve karışıklık matrisi (confusion matrix) gibi temel metriklerle analiz edilmiştir. Bu metrikler, özellikle dengesiz veri setlerinde modelin genel başarısını daha doğru yansıtmak açısından kritik öneme sahiptir.

SVM algoritması, özellikle küçük ve orta ölçekli veri setlerinde yüksek sınıflandırma doğruluğu ve genelleme kapasitesiyle literatürde yaygın olarak tercih edilmektedir. Geleneksel olarak Cortes ve Vapnik (1995) tarafından önerilen SVM, günümüzde hâlâ birçok kestirimci bakım uygulamasında etkinliğini korumaktadır. Ancak bu çalışmada kullanılan doğrusal olmayan sınıflandırma senaryoları göz önünde bulundurularak daha güncel incelemelere de yer verilmiştir.

Yang, Han ve Hwang (2005), döner makinelerde meydana gelebilecek farklı arıza türlerinin teşhisinde çok sınıflı destek vektör makineleri (SVM) kullanarak yüksek doğrulukta sınıflandırma gerçekleştirmiştir. Bu çalışma, kestirimci bakım uygulamalarında SVM algoritmasının birden fazla arıza sınıfını ayırt edebilme yeteneğini göstermesi açısından önemli bir referans niteliğindedir.

Destek Vektör Makineleri (SVM), doğrusal olmayan sınıflandırma problemlerinde etkinliği kanıtlanmış denetimli öğrenme algoritmaları arasında yer almaktadır. Chang ve Lin (2011) tarafından geliştirilen LIBSVM kütüphanesi, bu algoritmanın farklı çekirdek fonksiyonlarıyla geniş veri kümelerine uygulanabilmesini sağlayan güvenilir bir araç olarak literatürde yaygın biçimde kullanılmaktadır.

Batur, Zhou ve Chan (2002), destek vektör makinelerinin (SVM) sistem tanıma ile kombinlenerek bir ısı eşanjöründe arıza tespiti amacıyla uygulanabileceğini göstermiştir. Bu çalışma, SVM'nin kestirimci bakım süreçlerinde gerçek zamanlı arıza sınıflandırması için uygun bir teknik olduğunu ortaya koymaktadır.

Analiz sonucunda elde edilen sınıflandırma çıktıları, modelin arıza tahmini konusunda dengeli, güvenilir ve pratik bir yaklaşım sunduğunu ortaya koymuştur. Özellikle F1-score ve ROC eğrisi sonuçları, modelin hem arıza tespiti doğruluğu hem de düşük hata oranları açısından uygulanabilir bir çözüm sunduğunu göstermektedir.

5.2.2. Karar ağacı (Decision) ile arıza tahmini

Karar Ağaçları (Decision Tree – DT), sınıflandırma ve regresyon problemlerinde sıkça kullanılan, yorumlanabilirliği yüksek ve işlem yükü düşük olan denetimli öğrenme algoritmalarındandır. Bu çalışmada, arıza tahmini amacıyla oluşturulan 3000 kayıtlık

sentetik veri seti üzerinden DT algoritması kullanılarak analiz gerçekleştirilmiştir. Eğitim ve test veri ayrımı, önceki analizlerle tutarlı şekilde %70 (2100 kayıt) eğitim, %30 (900 kayıt) test olarak yapılmıştır. Model eğitimi Python programlama dili kullanılarak, scikit-learn kütüphanesi üzerinden gerçekleştirilmiştir. Karar Ağacı analizinin başarımları sonucu Tablo 5.3’de özetlenmiştir.


Tablo 5.3. Karar Ağacı analizi test verisindeki başarımları sonucu

Ölçüt	Değer
Doğruluk (Accuracy)	%93.3
F1 Skoru	0.659
AUC (ROC Eğrisi Altındaki Alan)	0.802

Doğruluk (Accuracy): Karar ağacı algoritmasıyla yapılan sınıflandırma sonucunda doğruluk oranı %93.3 olarak elde edilmiştir. Bu oran, test verisindeki tüm tahminlerin %93.3’ünün doğru sınıflandırıldığını göstermektedir. Ancak dengesiz veri setlerinde doğruluk oranı tek başına yeterli olmayabilir. Bu nedenle modelin performansı daha ayrıntılı ölçütlerle de değerlendirilmiştir.


F1 Skoru: Bu analizde F1 skoru 0.659 olarak hesaplanmıştır. F1 skoru, kesinlik (precision) ve duyarlılık (recall) değerlerinin harmonik ortalamasıdır. Özellikle arızalı sınıfların doğru tespiti gereken senaryolarda F1 skoru önemli bir ölçüttür. 0.659’luk değer, modelin arızalı kayıtları tanıma konusunda makul seviyede bir performans sergilediğini göstermektedir.

Karışıklık Matrisi (Confusion Matrix): Şekil 5.8’de görüldüğü üzere karışıklık matrisine göre; doğru negatif (TN): 782, Yanlış Pozitif (FP): 27, yanlış negatif (FN): 33, doğru pozitif (TP): 58’dir. Bu değerler, modelin özellikle arızasız kayıtları doğru tahmin etme konusunda başarılı olduğunu (TN = 782), ancak bazı arızalı kayıtları kaçırdığını (FN = 33) ortaya koymaktadır. FN değerinin yüksek olması, bazı arızaların gözden kaçtığını ve bu nedenle bakım kararlarında dikkat edilmesi gerektiğini gösterir.



Şekil 5.9. Karar ağaçları analizi karışıklık matrisi

ROC Eğrisi ve AUC: ROC (Receiver Operating Characteristic) eğrisi, modelin farklı eşik değerleri altında pozitif sınıfı ne kadar doğru tespit ettiğini gösterir. Bu çalışmada elde edilen AUC (Area Under Curve) değeri 0.802'dir. Bu değer, modelin arızalı ve arızasız sınıfları ayırt etme becerisinin oldukça yüksek olduğunu göstermektedir.



Şekil 5.10. Karar ağaçları analizi ROC eğrisi

Modelin sınıflandırma performansı genel olarak değerlendirildiğinde, karar ağaçları algoritması, açıklanabilirliği yüksek ve işlem gücü gereksinimi düşük olan yapısıyla kestirimci bakım uygulamaları için uygun bir yöntemdir. Elde edilen

sınıflandırma çıktıları, bu algoritmanın dengesiz veri setlerinde tatmin edici sonuçlar verdiğini ve bakım planlama kararlarında destekleyici olarak kullanılabileceğini göstermektedir.

Dos Santos ve diğerleri (2017), endüksiyon motorlarında stator sargısı kısa devrelerini Random Forest algoritmasıyla başarıyla tespit etmiş ve karar ağaçlarının kestirimci bakım uygulamalarında güvenilir bir yöntem olduğunu ortaya koymuştur.

5.2.3. Yapay sinir ağı (ANN) ile arıza tahmini

Yapay Sinir Ağları (ANN), insan beyninin öğrenme sürecinden esinlenerek geliştirilen, çok katmanlı yapılarla veri içindeki karmaşık ilişkileri modelleyebilen güçlü bir denetimli öğrenme algoritmasıdır. Bu çalışmada, kestirimci bakım kapsamında oluşturulan 3000 kayıtlık sentetik veri seti üzerinde ANN algoritması kullanılarak arıza tahmini gerçekleştirilmiştir. Modelin eğitimi %70 (2100 kayıt), testi ise %30 (900 kayıt) oranında veri bölünmesiyle yapılmıştır. Sıcaklık, titreşim ve fan hızı değişkenleri giriş parametreleri olarak kullanılmış; hedef değişken ise 0 (arıza yok) ve 1 (arıza var) olarak etiketlenmiştir. Model eğitimi öncesinde tüm değişkenler 'StandardScaler' yöntemiyle normalize edilmiştir. Eğitim ve analiz süreçleri Python ortamında TensorFlow kütüphanesi kullanılarak gerçekleştirilmiştir. Karar Ağacı analizinin başarımlı sonucu Tablo 5.4'de özetlenmiştir.


Tablo 5.4. Yapay sinir ağı analizi test verisindeki başarımlı sonucu

Ölçüt	Değer
Doğruluk (Accuracy)	%95.0
F1 Skoru	0.73
AUC (ROC Eğrisi Altındaki Alan)	0.975

Doğruluk (Accuracy): ANN modeli ile yapılan sınıflandırma sonucunda doğruluk oranı %95 olarak elde edilmiştir. Bu oran, 900 test örneğinin %95'ünün doğru şekilde tahmin edildiğini göstermektedir. Ancak doğruluk tek başına, özellikle dengesiz veri setlerinde yeterli bir değerlendirme ölçütü değildir.


F1 Skoru: Bu analizde F1 skoru 0.73 olarak hesaplanmıştır. F1 skoru, kesinlik (precision) ve duyarlılık (recall) oranlarının harmonik ortalamasıdır. Modelin arızalı sınıfı ne derece başarılı tespit ettiğini yansıtan bu değer, ANN modelinin dengesiz verilerde arıza tespitinde makul bir performans sergilediğini göstermektedir.

Karışıklık Matrisi (Confusion Matrix): Şekil 5.10’da gösterildiği üzere, ANN modeli test verisi üzerinde $TN = 793$, $FP = 16$, $FN = 29$ ve $TP = 62$ tahmininde bulunmuştur. Bu sonuçlar, modelin arızasız kayıtları yüksek başarıyla sınıflandırabildiğini, ancak bazı arızaları gözden kaçırdığını göstermektedir. Özellikle yanlış negatiflerin ($FN = 29$) varlığı, modelin bazı arızalı kayıtları “arıza yok” olarak tahmin ettiğini ifade eder. Buna karşın yanlış pozitif sayısının 16 olması, modelin bazı durumlarda gereksiz bakım alarmları üretebileceğini de ortaya koymaktadır.



Şekil 5.11. *Yapay sinir ağı analizi karışıklık matrisi*

ROC Eğrisi ve AUC: ROC eğrisi, modelin çeşitli eşik değerlerinde duyarlılık (true positive rate) ile yanlış alarm oranını (false positive rate) karşılaştırarak gösterir. Bu analizde AUC değeri 0.975 olarak elde edilmiştir. Bu yüksek değer, ANN algoritmasının pozitif ve negatif sınıflar arasında güçlü bir ayırım yeteneğine sahip olduğunu ortaya koymaktadır. Şekil 5.11’de modelin ROC eğrisi sunulmuştur.



Şekil 5.12. *Yapay sinir ağı ROC eğrisi*

Modelin sınıflandırma performansı genel olarak değerlendirildiğinde, ANN algoritması, doğruluk, F1 skoru ve ROC eğrisi gibi metriklerde yüksek başarı göstermiştir. Özellikle sistematik öğrenme kabiliyeti ve nöral katman yapısı sayesinde karmaşık ilişkilere dayanan arıza tahminlerinde güvenilir sonuçlar üretmektedir. Ancak, modelin FN oranı göz önünde bulundurulduğunda, bazı kritik arızaların gözden kaçabileceği de hesaba katılmalıdır. Bu nedenle ANN algoritması, diğer algoritmalarla birlikte değerlendirilerek bütüncül bir karar destek sistemine entegre edilmelidir.

Yapay sinir ağı modellerinin doğruluğunu artırmak amacıyla farklı eğitim algoritmalarının karşılaştırmalı olarak değerlendirilmesi, model optimizasyonu açısından önemlidir. Plumb ve diğerleri (2005), üç farklı ANN yazılımı ve dört sınıf eğitim algoritmasını karşılaştırarak bu alandaki optimizasyon yaklaşımlarına ışık tutmuştur.

Meyer (2021), çok hedefli yapay sinir ağlarına dayalı bir erken arıza tespit modeli geliştirmiş ve bu yaklaşımın endüstriyel veriler üzerinden olası arızaların önceden belirlenmesinde yüksek doğruluk sağladığını göstermiştir.

Bansal, Evans ve Jones (2004), makine sistemlerinde kullanılan gerçek zamanlı kestirimci bakım yaklaşımını tanıtarak, hareket akım imzası (motion current signature) ile sistem parametrelerinin yapay sinir ağı temelli tahminini gerçekleştirmişlerdir.

Aydın ve Güldamlaşoğlu (2017), büyük ölçekli veri işleme platformu Spark üzerinde LSTM ağlarını kullanarak motorun çalışma durumu sınıflandırmasını başarıyla gerçekleştirmiştir. NASA C-MAPSS verileri kullanılarak model yaklaşık %85 doğrulukla arıza öncesi uyarı sağlamıştır.

5.2.4. Uzun kısa süreli bellek (LSTM) ile arıza tahmini

Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ağırları, özellikle zaman serisi verilerle yapılan kestirimci bakım analizlerinde yaygın olarak kullanılan bir yapay sinir ağı mimarisidir. Bu çalışmada, oluşturulan sentetik veri seti kullanılarak arıza tahmini için LSTM modeli geliştirilmiştir. Modelin eğitimi ve testi için veri seti %70 (2100 kayıt) eğitim ve %30 (900 kayıt) test olarak ayrılmıştır. Model giriş değişkenleri olarak sıcaklık, titreşim ve fan hızı kullanılmıştır. Veriler normalize edilerek modele uygulanmıştır. Model TensorFlow ve scikit-learn kütüphaneleri kullanılarak Python ortamında geliştirilmiştir.


Tablo 5.5. Uzun kısa süreli bellek analizi test verisindeki başarımlar sonucunu

Ölçüt	Değer
Doğruluk (Accuracy)	%96.1
F1 Skoru	0.7904
AUC (ROC Eğrisi Altındaki Alan)	0.9834

Doğruluk (Accuracy): LSTM algoritması ile gerçekleştirilen sınıflandırma sonucunda Tablo 5.5.'de görüldüğü üzere doğruluk oranı %96.1 olarak elde edilmiştir. Bu oran, modelin test verisindeki doğru sınıflandırma oranını ifade etmektedir.


F1 Skoru: LSTM modeli için hesaplanan F1 skoru 0.7904'tür. Bu değer, modelin pozitif sınıfı (arıza) tanıma başarısını göstermektedir. Dengesiz veri setlerinde F1 skoru daha güvenilir bir metrik olarak kabul edilir.

Karışıklık Matrisi (Confusion Matrix): Şekil 5.12'de görüldüğü üzere $TN = 799$, $FP = 11$, $FN = 24$ ve $TP = 66$ olarak hesaplanmıştır. Bu sonuçlara göre model, arızalı kayıtları büyük ölçüde doğru sınıflandırmış; 24 yanlış negatif tahmini, kritik arızaların gözden kaçma riskini gösterirken, düşük yanlış pozitif sayısı sistemin gereksiz bakım alarmlarını minimize ettiğini ortaya koymaktadır.



Şekil 5.13. Uzun kısa süreli bellek analizi karışıklık matrisi

ROC Eğrisi ve AUC: ROC eğrisi üzerindeki değerlendirmede, AUC değeri 0.9834 olarak hesaplanmıştır. Bu yüksek değer, modelin arızalı ve arızasız sınıfları ayırt etme kabiliyetinin oldukça yüksek olduğunu göstermektedir. Özellikle bakım sistemlerinde erken teşhis ve güvenilir sınıflandırma yeteneği bakım kararlarını desteklemek açısından kritik öneme sahiptir. Şekil 5.13'te modelin ROC eğrisi sunulmuştur.



Şekil 5.14. Uzun kısa süreli bellek ROC eğrisi

Modelin sınıflandırma performansı genel olarak değerlendirildiğinde, LSTM modeli, zaman serisi veriler üzerinde başarılı bir sınıflandırma performansı sergilemiş ve özellikle ROC eğrisi, F1 skoru ve doğruluk oranı gibi metrikler dikkate alındığında güvenilir bir kestirimci bakım aracı olarak değerlendirilebilir.

LSTM tabanlı modellerin özellikle zaman serisi tabanlı arıza tespit uygulamalarında yüksek doğruluk sağladığı literatürde birçok çalışmayla ortaya konmuştur. Du ve diğerleri (2024), aero-motor sistemlerinde uzun-kısa süreli bellek (LSTM) otomatik kodlayıcı ile öz-dikkat (self-attention) mekanizmasını entegre ederek arıza tespitinde yüksek doğruluk sağlayan bir model geliştirmiştir. Bu yaklaşım, SCADA veya benzeri zaman serisi verilerinin kullanımıyla bakım süreçlerinin daha proaktif hale gelmesine önemli katkı sağlamaktadır.

Liu ve diğerleri (2021), çok kademeli uçak motorlarında LSTM ve kümeleme tabanlı yaklaşımları birleştirerek kalan ömür tahmininde yüksek doğruluk elde etmiş ve bu yöntemin kestirimci bakım uygulamalarında etkinliğini ortaya koymuştur.

Zaman serisi verilerinde anomali tespiti amacıyla LSTM tabanlı modellerin kullanımı, özellikle arıza belirtilerinin erken tespitinde güçlü sonuçlar vermektedir. Malhotra ve diğerleri (2015), bu yaklaşımın özellikle kestirimci bakım senaryolarında yüksek doğrulukla anomalileri belirleyebildiğini ortaya koymuştur.

Wu, Huang ve Sutherland (2020), ekipman arızalarının çevresel sonuçlarını önlemeye yönelik olarak uzun-kısa süreli bellek (LSTM) temelli kestirimci bakım modellerinin etkinliğini vurgulamış ve üretim süreçlerinde sürdürülebilirliğe katkı sağlayan bir yapay zeka uygulaması önermiştir.

Kim ve Choi (2021), kestirimci bakım uygulamalarında LSTM modellerinin performansını artırmak amacıyla tasarım parametrelerinin optimizasyonunu incelemiş ve özellikle zaman serisi verilerde doğru parametre seçimlerinin tahmin başarısını önemli ölçüde etkilediğini vurgulamıştır.

Karmiani ve diğerleri (2019), finansal zaman serisi verisi üzerinde geriye yayılım (backpropagation), SVM, LSTM ve Kalman filtresi gibi algoritmaların performanslarını karşılaştırmalı olarak analiz etmiş; LSTM'nin özellikle zaman bağımlı verilerde daha istikrarlı tahmin sonuçları verdiğini raporlamıştır. Bu sonuç, tez kapsamında yapılan analizlerle de uyumludur ve kestirimci bakım senaryolarında LSTM'nin potansiyelini vurgular niteliktedir.

LSTM mimarisi, zaman serisi verilerinin uzun süreli bağımlılıklarını öğrenme yeteneği sayesinde kestirimci bakım uygulamalarında sıkça tercih edilmektedir. Jiang ve diğerleri (2022), klasik LSTM yapısını geliştirerek önerdikleri A2-LSTM modeli ile endüstriyel ekipmanlarda arıza tahmini doğruluğunu önemli ölçüde artırdıklarını göstermiştir. Bu gelişme, bakım kararlarının zamanında alınmasına olanak tanıyarak bakım maliyetlerinin azaltılmasına katkı sağlamaktadır.

Huang ve diğerleri (2022), petrol üretiminde kuyu performansının tahmininde LSTM ağlarının doğruluğunu analiz ederek, bu algoritmanın endüstriyel sistemlerde yüksek tahmin başarısı sağladığını ortaya koymuştur.

Bruneo ve De Vita (2019), endüstri 4.0 ortamında turbofan motorların kalan faydalı ömrünü (RUL) LSTM ağları ile tahmin ederek yüksek doğruluk elde etmiş ve bu yaklaşımın kestirimci bakım süreçlerine entegrasyon potansiyelini göstermiştir.

Aliyev (2025), LSTM ve GRU modellerini bir açıklanabilir yapay zekâ yaklaşımıyla birleştirerek, iktisadi veri setleri üzerinde SHAP tabanlı model yorumlanabilirliği sağlamıştır. Bu yönüyle çalışma, kestirimci bakım sistemlerinde model kararlarının operatör ve uzman kullanıcılar tarafından anlaşılabilir olmasını destekleyen önemli bir referansta bulunmaktadır.

5.3. Yapay Zeka Algoritmalarının Karşılaştırılması

Bu bölümde, çalışma kapsamında kullanılan dört farklı yapay zeka algoritmasının (SVM, Decision Tree, Yapay Sinir Ağları (ANN) ve Uzun Kısa Süreli Bellek (LSTM)) arıza tahmini performansları karşılaştırılmaktadır. Karşılaştırmada kullanılan temel ölçütler: doğruluk (accuracy), F1 skoru, ROC eğrisi (Receiver Operating Characteristic Curve) ve karışıklık matrisi (confusion matrix) olmuştur.

5.3.1. Doğruluk (Accuracy) karşılaştırması

Doğruluk oranları, algoritmaların test verileri üzerindeki genel başarısını göstermektedir. Elde edilen doğruluk değerleri Tablo 5.6'da sunulmuştur.

Tablo 5.6. Algoritmaların doğruluk karşılaştırması

Algoritma	Doğruluk Oranı (%)
SVM	96.3
Decision Tree	93.3
ANN	95.0
LSTM	96.1

Tablodan da görüleceği üzere, en yüksek doğruluk oranı SVM algoritması ile elde edilmiştir. LSTM ve ANN modelleri benzer başarı düzeyleri sunarken, Decision Tree modeli diğer algoritmalara göre bir miktar daha düşük performans göstermiştir. Ancak tüm modellerin %93'ten yüksek doğruluk değerlerine sahip olması, sistemin genel olarak güvenilir tahminler yaptığını göstermektedir.

5.3.2. Algoritmaların F1 skoru açısından karşılaştırılması

F1 skoru, bir sınıflandırma modelinin kesinlik (precision) ve duyarlılık (recall) ölçütlerinin harmonik ortalaması olarak tanımlanmakta olup; özellikle dengesiz veri setlerinde modelin pozitif sınıfı (örneğin arıza sınıfı) ne kadar iyi tahmin ettiğini gösteren güvenilir bir ölçüt olarak öne çıkmaktadır (Saito and Rehmsmeier, 2015). Bu çalışmada kullanılan veri setinde "arıza var" sınıfı, "arıza yok" sınıfına kıyasla daha nadir görüldüğünden dolayı F1 skoru, model başarımının değerlendirilmesinde kritik bir rol oynamıştır. Aşağıdaki Tablo 5.7'de, dört farklı algoritmaya ait F1 skorlarının karşılaştırması görülmektedir.

Tablo 5.7. Algoritmaların F1 skoru karşılaştırması

Algoritma	F1 Skoru
SVM	0.7900
Decision Tree	0.6590
ANN	0.7300
LSTM	0.7904

Tablo 5.7'ye göre, en yüksek F1 skoru LSTM algoritması ile elde edilmiştir (0.7904). Bu sonuç, LSTM'nin zaman serisi verilerinde örüntüleri tanıma kabiliyetinin yüksek olduğunu ve özellikle arızalı örnekleri doğru sınıflandırmada etkili olduğunu göstermektedir. SVM algoritması, LSTM'ye çok yakın bir skor (0.7900) elde ederek güçlü bir alternatif sunmuştur. Bu durum, SVM'nin küçük veri setlerinde ve yüksek boyutlu uzaylarda karar sınırlarını başarıyla öğrenebilme yeteneğinden kaynaklanmaktadır.

Yapay Sinir Ağı (ANN) algoritması ise 0.73'lük bir F1 skoru ile ortalama bir başarı göstermiştir. Bu durum, ANN'in çok katmanlı yapısına rağmen zaman bağımlı verilerde (sequence data) LSTM kadar güçlü olmadığını ortaya koymaktadır. Karar Ağacı (Decision Tree) modeli ise 0.659 F1 skoru ile en düşük başarıyı göstermiştir. Bu sonuç,

Decision Tree algoritmalarının dengesiz sınıflarda overfitting'e daha yatkın olmasından ve karmaşık ilişkileri modelleme konusunda sınırlı kalmasından kaynaklanabilir.

Genel olarak, LSTM ve SVM modellerinin arıza sınıfını tanımada yüksek performans gösterdiği; ANN'in makul düzeyde bir başarı sağladığı; Decision Tree algoritmasının ise sınırlı kaldığı söylenebilir. F1 skorlarının %0.65 ile %0.79 arasında değiştiği göz önüne alındığında, özellikle arıza tespiti gibi kritik güvenlik uygulamalarında LSTM ve SVM algoritmaları daha tercih edilebilir modeller olarak öne çıkmaktadır.

5.3.3. Algoritmaların karışıklık matrisi açısından karşılaştırılması

Karışıklık matrisi (confusion matrix), sınıflandırma algoritmalarının başarımını değerlendirirken sıklıkla kullanılan temel araçlardan biridir. Bu matriste; True Negative (TN), False Positive (FP), False Negative (FN) ve True Positive (TP) değerleri analiz edilerek modellerin doğru ve hatalı sınıflandırma yetenekleri ayrıntılı şekilde değerlendirilir. Tablo 5.8'de algoritmaların test verisindeki karışıklık matrisi değerleri özetlenmiştir:

Tablo 5.8. Algoritmaların karışıklık matrisi karşılaştırması

Algoritma	TN	FP	FN	TP
SVM	804	6	27	63
Decision Tree	782	27	33	58
ANN	793	16	29	62
LSTM	799	11	24	66

SVM algoritması, 804 sağlam veriden 804'ünü doğru sınıflandırarak (TN = 804) en yüksek negatif sınıf tanıma başarısını göstermiştir. Ayrıca yalnızca 6 adet FP üretmesi, modelin gereksiz bakım alarmı üretme riskinin düşük olduğunu ortaya koyar. Ancak 27 adet FN ile bazı arızalı kayıtları gözden kaçırdığı da görülmektedir.

Decision Tree modeli, TN = 782 ve FP = 27 sonucu ile sağlam kayıtları tanıma konusunda en düşük performansa sahiptir. Aynı zamanda FN = 33 değeri ile bazı arızalı verileri de “sağlam” olarak değerlendirmiştir. Bu durum, modelin hem yanlış alarmlar üretebildiğini hem de bazı arızaları tespit edemediğini göstermektedir.

ANN modeli, TN = 793 ve FP = 16 ile orta seviyede bir sağlam kayıt tanıma başarısı göstermiştir. Ancak FN = 29 ile bazı arızalı kayıtları yine yanlış sınıflandırmıştır. Bu

sonuç, ANN algoritmasının daha dengeli ancak hala dikkat edilmesi gereken bir yapıya sahip olduğunu ortaya koymaktadır.

LSTM algoritması ise $TN = 799$, $FP = 11$, $FN = 24$ ve $TP = 66$ değerleriyle oldukça dengeli bir yapı sunmaktadır. Düşük FP değeri sayesinde sistemin gereksiz yere bakım yapma olasılığı düşüktür. Aynı zamanda $TP = 66$ ile en fazla arızalı kaydı doğru tanımlayan model olmuştur. Bu yönüyle kestirimci bakım uygulamalarında yüksek güvenilirliğe sahip bir model olarak öne çıkmaktadır.

Sonuç olarak, SVM ve LSTM modelleri, özellikle TN ve TP değerleri açısından güçlü performans sergilemiştir. Decision Tree modeli, yüksek FP ve FN değerleriyle daha düşük güven sunarken, ANN ise orta düzeyde dengeli sonuçlar üretmiştir. Bu analiz, sadece doğruluk değil, arızaları tespit edebilme (TP) ve hatalı alarm üretmeme (FP) gibi kriterlerin de sistem güvenliği açısından ne kadar önemli olduğunu göstermektedir.

Bazı çalışmalarda kestirimci bakım için denetimsiz öğrenme yöntemleri de önerilmiştir. Örneğin Rodriguez ve diğerleri (2023), SCADA verileri üzerinde K-means algoritması kullanarak rüzgar türbinlerinin benzer davranış kümelerini analiz etmiş ve bu gruplar üzerinden arıza öngörüsü geliştirmiştir.

Makine öğrenmesi tabanlı kestirimci bakım sistemlerinin başarımı, farklı sınıflandırıcıların birlikte değerlendirilmesiyle artırılabilir (Susto ve diğerleri, 2014).

5.3.4. Algoritmaların ROC eğrisi ve AUC açısından karşılaştırılması

ROC eğrisi (Receiver Operating Characteristic), sınıflandırma algoritmalarının farklı eşik değerlerinde ne kadar iyi performans gösterdiğini grafiksel olarak sunar. Bu eğri altında kalan alan (AUC – Area Under Curve), modelin genel sınıflandırma başarısını tek bir metrik ile özetleyen güçlü bir göstergedir.

Tablo 5.9’da görüldüğü üzere, en yüksek AUC değeri 0.9834 ile LSTM modeline aittir. Bu durum, LSTM'nin sınıflandırmalarda farklı eşik değerlerinde dahi istikrarlı bir şekilde yüksek duyarlılığa ve özgüllüğe sahip olduğunu göstermektedir. ANN modeli 0.975 ile LSTM'yi yakından takip etmektedir. Bu iki model, özellikle dengesiz veri setlerinde güvenilir sınıflandırma yetenekleri sayesinde öne çıkmaktadır (Saito and Rehmsmeier, 2015).

Tablo 5.9. *Algoritmaların ROC eğrisi ve AUC karşılaştırması*

Algoritma	AUC
SVM	0.9650
Decision Tree	0.8020
ANN	0.9750
LSTM	0.9834

SVM algoritması ise 0.965 AUC değeri ile yine oldukça başarılı bir performans sergilemiş; ancak LSTM ve ANN'e kıyasla marjinal olarak daha düşük kalmıştır. Buna karşın, Decision Tree modeli 0.802 AUC skoru ile diğer modellere kıyasla belirgin bir şekilde geride kalmıştır. Bu da karar ağacının, sınıflandırma eşikleri değiştiğinde tutarlı ve dengeli bir performans sergileyemediğini ortaya koymaktadır.

Sonuç olarak, AUC değeri bakımından LSTM modeli en güvenilir sınıflandırma modelidir. Bu, özellikle arıza tespiti gibi yüksek doğruluk ve duyarlılık gerektiren kestirimci bakım uygulamalarında kritik öneme sahiptir.

5.3.5. Genel değerlendirme ve yorum

Bu çalışmada, uçak motorlarına ilişkin arıza tahmini amacıyla dört farklı yapay zeka algoritması karşılaştırılmıştır: Destek Vektör Makineleri (SVM), Karar Ağacı (DT), Yapay Sinir Ağı (ANN) ve Uzun Kısa Süreli Bellek (LSTM). Analizler doğruluk (accuracy), F1 skoru, ROC eğrisi ve AUC değeri gibi performans ölçütleri üzerinden gerçekleştirilmiştir.

Analiz sonuçlarına göre en yüksek F1 skoru 0.7904 ile LSTM algoritmasında elde edilmiştir. F1 skoru, özellikle arıza gibi nadir sınıfların doğru tahmini açısından en kritik ölçütlerden biridir (Saito ve Rehmsmeier, 2015). Bu sonuç, LSTM modelinin dengesiz veri setlerinde hem duyarlılık (recall) hem de kesinlik (precision) açısından dengeli bir performans sergilediğini göstermektedir. LSTM'nin başarısı, zaman serisi verilerindeki bağımlılıkları öğrenebilme kapasitesi ve belleğe dayalı yapısıyla da desteklenmektedir.

İkinci en yüksek F1 skoru 0.79 ile SVM algoritmasında gözlemlenmiştir. Bu sonuç, SVM'in düşük boyutlu ve net sınırlarla ayrılabilen veri setlerinde istikrarlı bir sınıflandırma başarısı sunduğunu göstermektedir. Özellikle yanlış pozitif oranının düşük olması, SVM'in bakım sistemlerinde gereksiz alarm üretme ihtimalini azaltan bir yapıya sahip olduğunu ortaya koymuştur.

ANN algoritması 0.73 F1 skoru ile üçüncü sırada yer almıştır. Her ne kadar doğruluk oranı yüksek olsa da, F1 skorunun görece daha düşük kalması modelin bazı arızalı sınıfları kaçırdığını göstermektedir. Bu durum, literatürde de ifade edildiği gibi ANN'lerin büyük ve dengeli veri setlerinde güçlü performans gösterdiği; ancak sınıf dağılımının dengesiz olduğu durumlarda duyarlılığının zayıflayabileceğini desteklemektedir.

En düşük F1 skoru ise 0.659 ile Karar Ağacı (DT) algoritmasında elde edilmiştir. Karar ağaçları algoritmalarının anlaşılabilir ve hızlı yapısı avantaj sağlasa da, genelleme performanslarının sınırlı olması nedeniyle dengesiz veri setlerinde arızalı kayıtların tespitinde zayıf kaldığı gözlemlenmiştir.

Tüm metrikler birlikte değerlendirildiğinde, LSTM algoritması bu çalışmanın genelinde en başarılı model olarak öne çıkmıştır. Ancak eğitim süresi, hesaplama maliyeti ve algoritma karmaşıklığı gibi etkenler de uygulama tercihinin belirlemede rol oynamalıdır. Örneğin ANN, daha az karmaşık sistemlerde hızlı ve tatmin edici sonuçlar sunabilirken; SVM, küçük ve dengeli veri setleri için ideal bir çözüm sunmaktadır. DT algoritması ise yorumlanabilirliğiyle öne çıkmasına rağmen, düşük sınıflandırma başarısı nedeniyle tek başına önerilmemektedir.

SVM ve ANN algoritmalarının çeşitli tahminleme problemlerinde performans karşılaştırmaları, özellikle zaman serisi verilerde belirgin farklılıklar gösterdiğini ortaya koymaktadır (Kurani ve diğerleri, 2023).

Arıza tespiti problemlerinde SVM ve yapay sinir ağları gibi algoritmaların başarımı, modelin eğitilme biçimi ve parametre seçimlerine yüksek derecede bağlıdır. Jack ve Nandi (2002), genetik algoritmalarla desteklenen SVM ve ANN modellerini karşılaştırarak, doğru parametre ayarlarının sınıflandırma başarımını anlamlı şekilde artırdığını göstermiştir. Bu durum, kestirimci bakım sistemlerinde doğru model yapılandırmasının kritik olduğunu göstermektedir.

Yapay sinir ağları, destek vektör regresyonu ve derin öğrenme yöntemlerinin çok çeşitli mühendislik alanlarında başarıyla uygulandığı bildirilmektedir (Zhang ve diğerleri, 2018).

Chhajer, Shah ve Kshirsagar (2022), borsa tahmini özelinde gerçekleştirdikleri analizlerde LSTM'nin uzun vadeli bağımlılıkları daha iyi modellediğini, ANN'nin hızlı öğrenme sunduğunu ve SVM'nin düşük boyutlu veri setlerinde yüksek doğruluk

sağladığını göstermiştir. Bu değerlendirmeler, kestirimci bakım uygulamalarında da benzer algoritma seçimlerinin yapılabileceğini ortaya koymaktadır.

Sonuç olarak, yapay zeka algoritması seçimi yalnızca tek bir başarı metriğine dayandırılmamalıdır. Uygulama gereksinimleri, veri yapısı ve bakım stratejisine göre farklı metriklerin (örneğin accuracy, F1-score ve ROC-AUC gibi) birlikte değerlendirilmesi gerekir (Saito ve Rehmsmeier, 2015; Chicco ve Jurman, 2020).

5.4. Maliyet Analizi

Kestirimci bakım sistemleri, özellikle havacılık gibi yüksek güvenlik ve yüksek maliyet unsurlarının bulunduğu sektörlerde, operasyonel etkinliği artırmanın yanı sıra maliyetleri azaltma potansiyeli taşımaktadır. Bu tez kapsamında geliştirilen SCADA tabanlı kestirimci bakım sistemi, sadece teknik doğruluk açısından değil, aynı zamanda ekonomik getiriler bakımından da değerlendirilmiştir.

Geleneksel arıza sonrası bakım yöntemlerinde, arıza meydana geldikten sonra gerçekleştirilen onarım süreçleri hem iş gücü maliyetlerini artırmakta hem de sistem duruş süresince önemli operasyonel kayıplara yol açmaktadır. Bu yaklaşımlarda sistemlerin beklenmedik şekilde devre dışı kalması, hem güvenlik hem de verimlilik açısından ciddi riskler doğurmaktadır. Literatürde, kestirimci bakım uygulamalarının bu olumsuzlukları azaltmada etkili olduğu ve bakım süreçlerini daha planlı ve öngörülebilir hâle getirdiği vurgulanmaktadır. Özellikle yapay zekâ destekli kestirimci modellerin, sistem parametrelerinin sürekli izlenmesiyle potansiyel arızaların önceden tespit edilmesine olanak tanıdığı ve bakım operasyonlarının daha etkin şekilde yönetilmesini sağladığı çeşitli çalışmalarda belirtilmiştir (Mobley, 2002; Lee ve diğerleri, 2015).

Uçak bakım süreçlerinin maliyet açısından analizi, özellikle verimlilik odaklı bakım stratejilerinin değerlendirilmesinde önemli bir rol oynamaktadır. Mofokeng ve diğerleri (2020), farklı bakım türlerinin maliyet ve süre etkilerini inceleyerek, planlı bakımın toplam operasyonel yük üzerindeki katkılarını ortaya koymuştur.

Bu çalışmada geliştirilen SVM, ANN, LSTM ve Decision Tree modellerinin ortalama F1 skorları sırasıyla 0.79, 0.73, 0.7904 ve 0.659 olarak hesaplanmıştır. Bu oranlar, modellerin arıza tespitindeki başarılarını doğrudan yansıtmaktadır. Aşağıda Tablo 5.10'da gösterilen varsayımlarla oluşturulan örnek senaryo, bu başarıların ekonomik karşılığını göstermektedir.

Tablo 5.10. Maliyet analizi için örnek senaryo

Parametre	Değer
Uçak motoru başına ortalama bakım maliyeti (arıza sonrası)	40.000 USD
Duruş maliyeti (1 günlük)	30.000 USD
Toplam kayıt sayısı	3000
Gerçek arıza kayıt oranı	%10 (300 kayıt)
Modelin F1 skoru (örneğin: LSTM)	0,79
Doğru tespit edilen arızalı kayıt sayısı	≈ 237 kayıt
Önleyici bakım maliyeti	10.000 USD
Toplam potansiyel kazanç = (40.000+30.000-10.000)x237 = 60.000x237 = 14.220.000 USD	

Tablo 5.10'a göre, LSTM modeli kullanılarak elde edilen %79 başarı oranıyla varsayımlara dayalı yaklaşık 14,2 milyon USD'lik bir maliyet önlenebilirliği sağlanabilmektedir. Bu sonuçlar, model performans metriklerinin sadece akademik anlamda değil, işletme ekonomisi açısından da son derece kritik olduğunu göstermektedir.

Gilabert ve diğerleri (2017), simülasyon temelli analizler ile kestirimci bakım uygulamalarının geleneksel bakım yaklaşımlarına kıyasla daha düşük maliyetli ve daha sürdürülebilir çözümler sunduğunu göstermiştir. Bu tür analizler, bakım stratejilerinin yatırım geri dönüşü açısından değerlendirilmesini mümkün kılmaktadır.

Chu, Proth ve Wolff (1998), bakım kararı için tek birimlik değişim yaklaşımını temel alan modellemelerinde, ekipmanın arızalanmadan önce ne zaman değiştirilmesi gerektiğini maliyet ve risk açısından optimize etmişlerdir. Bu yaklaşım, modern kestirimci bakım sistemlerinin kuramsal temellerini oluşturan önemli bir yapı sunmaktadır.

5.5. SCADA Destekli Kestirimci Bakım Uygulaması

5.5.1. Veri toplama süreci

Uçak bakım süreçlerinde kestirimci bakım uygulamaları için gerekli olan sensör verileri genellikle SCADA sistemleri aracılığıyla toplanmaktadır. Bu çalışmada kullanılan veriler sıcaklık, titreşim ve hidrolik basınç gibi parametreleri içermektedir. Bu veriler, gerçek sistemlerde uçak motorlarının çeşitli kritik bölgelerine yerleştirilen sensörler aracılığıyla sürekli olarak izlenmektedir. SCADA sistemi, bu sensörlerden gelen verileri merkezi bir veritabanına aktarır ve böylece bakım operatörlerinin sistem durumu hakkında anlık bilgi sahibi olmaları sağlanır. Literatürde de SCADA

sistemlerinin, bakım yönetiminde veri güvenilirliği ve erişim hızını artırdığı birçok çalışmada vurgulanmıştır (Civerchia ve diğerleri, 2017).

5.5.2. Veri ön işleme adımları

SCADA sistemlerinden elde edilen ham veriler, genellikle gürültü, eksiklik veya uyumsuzluk içerebilir. Bu nedenle, yapay zeka algoritmalarına veri sunulmadan önce ön işleme adımlarına ihtiyaç duyulmaktadır. Bu çalışmada, eksik veriler kontrol edilmiş ve normalize edilerek ölçek farklılıkları ortadan kaldırılmıştır. Özellikle LSTM gibi sinir ağı temelli modellerin eğitimi sırasında veri ölçeklerinin dengede olması, öğrenme başarısını doğrudan etkilemektedir. Normalize işlemi ile tüm değişkenlerin ortalama ve standart sapma çerçevesinde benzer aralıklarda olması sağlanmış, böylece modelin her bir sensör verisini eşit önemde işlemesi mümkün hale getirilmiştir.

Veri madenciliği sürecinde kullanılan makine öğrenmesi algoritmalarının performansı, girdilerin uygun biçimde ölçeklendirilmesine doğrudan bağlıdır. Sujon ve diğerleri (2024), standardizasyon ve normalizasyon tekniklerinin, model doğruluğu ve açıklanabilir yapay zeka çıktıları üzerindeki etkilerini kapsamlı biçimde inceleyerek, her bir yaklaşımın kullanım senaryolarına ilişkin ampirik bulgular sunmuştur.

5.5.3. Algoritma kullanımı

Veri ön işleme sürecinin ardından, SCADA'dan gelen sensör verileri kullanılarak dört farklı yapay zeka algoritması ile kestirimci bakım analizi gerçekleştirilmiştir: Support Vector Machine (SVM), Decision Tree (DT), Artificial Neural Network (ANN) ve Long Short-Term Memory (LSTM). Tüm modeller aynı eğitim (%70) ve test (%30) veri bölmesi ile çalıştırılmış ve performans metrikleri (doğruluk, F1 skoru, ROC eğrisi ve karışıklık matrisi) hesaplanmıştır. LSTM modeli zaman serisi verilerde geçmiş bağımlılığı dikkate alarak öne çıkarken, DT modeli yorumlanabilirliği ile avantaj sağlamaktadır. Her algoritma, farklı yapıdaki veri setleri için çeşitli avantajlara sahiptir (Abdar ve diğerleri, 2021).

5.5.4. Eşik değeri seçimi

Bu çalışmada kullanılan veri seti, simülasyonla oluşturulmuş olup arıza skoru doğrudan kullanıcı tarafından belirlenmiştir. Bu nedenle eşik değeri manuel olarak belirlenmiştir. Kullanılan arıza skoru, belirli bir eşik değerinin üzerinde olan kayıtları

yüksek riskli (arıza potansiyeli yüksek) olarak sınıflandırmak amacıyla tasarlanmıştır. Bu bağlamda, veri %70 eğitim ve %30 test olarak ayrılmış ve model eğitimi gerçekleştirilmiştir. Test sonuçlarında, kullanılan eşik değerinin karar doğruluğu, F1 skoru, ROC eğrisi ve karışıklık matrisi ile analiz edilmiştir.

Gerçek dünya uygulamalarında ise eşik değeri genellikle sabit olarak belirlenmez. Bunun yerine, ROC eğrisi üzerindeki optimum eşik (örneğin Youden Index) ya da farklı hiperparametre optimizasyon teknikleriyle (Grid Search, Bayesian Optimization vb.) eşik değeri otomatik olarak optimize edilebilir. Ayrıca, bakım maliyeti ve risk yönetimi gibi unsurlar da dikkate alınarak sistemin False Positive ve False Negative değerleri dengeleyici şekilde çalışması sağlanabilir.

Saito and Rehmsmeier (2015), özellikle dengesiz veri setlerinde ROC eğrisi analizinin önemli olduğunu ve eşik değerinin kullanım amacına göre (yüksek duyarlılık veya özgüllük) seçilmesi gerektiğini belirtmektedir. Bu kapsamda, eşik değeri seçiminin yalnızca teknik bir karar değil, aynı zamanda operasyonel stratejilere bağlı bir unsur olduğu unutulmamalıdır.

5.5.5. Operatör müdahalesi ve bakım kaydı

SCADA sistemlerinin en büyük avantajlarından biri, insan müdahalesine olanak tanıyan görsel ve uyarı temelli ara yüzler sunmasıdır. Bu çalışmada, belirli bir eşik değerin aşılması durumunda SCADA sistemi, bakım operatörüne alarm üretmekte ve müdahale edilmesi gereken ekipmanı detaylı biçimde göstermektedir. Operatör, bu alarm üzerine bakım geçmişini kontrol edebilir, sistemde duruş kaydı oluşturabilir veya planlı bir müdahale başlatabilir. Tüm bu süreçler bakım yönetimi sistemine otomatik olarak kaydedilmekte, böylece hem bakım geçmişi izlenebilmekte hem de gelecekteki kestirimci bakım stratejileri için veri tabanı oluşturulmaktadır (Lee ve diğerleri, 2015). Bu yapı, sadece arızayı önceden tespit etmekle kalmaz, aynı zamanda insan faktörünü de sürece entegre eden kapalı döngü bir bakım sistemi oluşturur.


6. SCADA İLE UÇAK BAKIM SÜREÇLERİNDE KESTİRİMCİ BAKIM ANALİZİ

Uçak bakım süreçlerinde SCADA sistemlerinin kullanılması, kestirimci bakım faaliyetlerinin etkinliğini önemli ölçüde artırmaktadır. Bu bölümde SCADA tabanlı kestirimci bakım analizinin çalışma prensipleri, veri toplama ve analiz süreçleri ile sistem entegrasyonu detaylı olarak incelenecektir.

İşbilen ve Konar (2020), uçak alt sistemlerinin SCADA ile modellenmesi üzerine gerçekleştirdikleri çalışmada, bu sistemlerin uçuş güvenliği ve bakım planlaması açısından sunduğu katkıları ortaya koymuştur. Bu durum, kestirimci bakım uygulamalarının havacılığa entegrasyonunda SCADA tabanlı yaklaşımların önemini pekiştirmektedir.

6.1. SCADA-PdM Entegrasyonunun Genel Yapısı

SCADA sistemleri ile kestirimci bakım (Predictive Maintenance – PdM) algoritmalarının entegrasyonu, bakım süreçlerini hem operasyonel hem de analitik düzeyde optimize etmeye olanak tanır. Bu yapı; sensörlerden gelen verilerin merkezi sistemlere aktarılması, bu verilerin analiz edilmesi ve arıza ihtimaline karşı önleyici eylem önerilmesini içerir.




Şekil 6.1. SCADA-PdM entegrasyonunun genel yapısı

Temel işleyiş şu adımlarla gerçekleşir:

1. SCADA sistemine bağlı sensörlerden sürekli veri toplanır (sıcaklık, basınç, titreşim, akım vb.).
2. PLC veya RTU üzerinden bu veriler kontrol merkezine iletilir.
3. Toplanan veriler, önceden tanımlanmış eşik değerlerle karşılaştırılır.
4. Veriler kestirimci bakım algoritmalarına (AI/ML) yönlendirilir.
5. Anomaliler veya trend analizleri sonucunda arıza olasılığı hesaplanır.
6. Sistem, HMI ekranı ya da alarm sistemi ile operatöre erken uyarı verir.
7. Önleyici bakım planı otomatik olarak önerilir veya başlatılır.

6.2. SCADA-PdM Veri Akış Diyagramı

Aşağıda Şekil 6.2.'de tipik bir SCADA-PdM entegrasyonunun veri akışı örneklendirilmiştir:



Şekil 6.2. SCADA-PdM veri akış diyagramı

Şekil 6.2.'de görünen yapı, sistemin hem çevrim içi kontrol hem de çevrim dışı analiz yapabilmesini sağlar. Veriler yalnızca anlık değil, geçmişe dönük olarak da analiz edilerek uzun vadeli kestirim stratejileri geliştirilebilir.

6.3. Kullanılan Yapay Zekâ Algoritmaları

SCADA ile çalışan PdM sistemlerinde en sık kullanılan algoritmalar şunlardır:


- **Karar Ağaçları (Decision Trees):** Hızlı karar mekanizmaları için uygundur.
- **Destek Vektör Makineleri (SVM):** Arıza ve normal durumu sınıflandırmakta başarılıdır.
- **Yapay Sinir Ağları (ANN):** Karmaşık ilişkileri öğrenerek yüksek doğruluk sağlar.
- **Zaman Serisi Analizi (ARIMA, LSTM):** Özellikle sürekli ölçülen sıcaklık veya basınç gibi değerlerin tahmini için kullanılır.

6.4. Uygulama Senaryoları

1. Senaryo: Uçak Hidrolik Pompası Arızası

- Uçak bakım tesisinde, bir Boeing 737'nin hidrolik sistem pompası SCADA üzerinden sürekli izlenmektedir.
- Son 10 gündür SCADA sistemi, pompa basıncında dalgalanma ve akım değerlerinde istikrarsızlık tespit etmektedir.
- Bu veriler, SCADA'dan PdM algoritmasına aktarılır.
- ANN tabanlı analiz modeli, bu dalgalanmaların geçmişte %85 oranında pompa arızasına yol açtığını belirler.
- Sistem, bakım mühendislerine 3 gün içinde müdahale edilmezse pompanın arıza riski taşıdığına dair bir uyarı gönderir.
- Müdahale edilerek pompa değişimi yapılır, uçuş güvenliği sağlanır, olası AOG (Aircraft on Ground) durumu önlenmiş olur.

Aşağıda Şekil 6.3.'de farklı bir sistem bileşeni üzerinden tasarlanmış ikinci bir senaryo sunulmaktadır.



Şekil 6.3. Örnek senaryo akış diyagramı

2. Senaryo: Uçak motor rulmanı arızası

Şekil 7.3’de gösterilen örnek akış diyagramında, bir Airbus A320 tipi uçağın motor sistemlerinde, uçuş öncesi yapılan SCADA tabanlı otomatik kontroller sırasında motorun sağ alt bölümünde yer alan bir rulmanın titreşim değerlerinde olağandışı bir artış tespit edilmiştir. Bu artış, SCADA sistemine bağlı sensörler tarafından sürekli olarak izlenmekte ve sisteme gerçek zamanlı olarak iletilmektedir.

SCADA Sistemi Verileri: Titreşim sensörü tarafından alınan veriler, RTU aracılığıyla SCADA sunucusuna iletilmiş ve buradaki yazılım arayüzünde eşik değerin üzerine çıkan titreşim frekansları (yaklaşık $3 \times \text{RPM}$) bir alarm olarak tanımlanmıştır. SCADA sistemindeki veri izleme paneli bu durumu HMI ekranında kırmızı uyarı şeklinde göstermiştir.

Yapay Zekâ Analizi: Veriler, SCADA sistemine entegre çalışan bir LSTM (Long Short-Term Memory) algoritmasına yönlendirilmiştir. Algoritma, geçmiş altı aylık verilerle karşılaştırmalı analiz yaparak bu yükselmenin normal dışı olduğunu ve arıza ihtimalinin yüksek olduğunu hesaplamıştır. Arıza oluşma olasılığı %87 olarak tahmin edilmiştir.

Operatör Uyarısı ve Raporlama: SCADA HMI arayüzü, ilgili bakım mühendislerine anlık bir bildirim göndermiştir. Aynı zamanda bakım yönetim sistemi, oluşturulan yapay zekâ raporunu PDF formatında arşivlemiş ve ilgili arıza kodu ile sistem üzerine loglanmıştır.

Müdahale Kararı ve Sonuç: Operatör, AI sisteminin önerisi doğrultusunda uçağın uçuş planını iptal etmiş ve rulman sisteminin değiştirilmesi kararlaştırılmıştır. Bu müdahale sayesinde rulmanın uçuş sırasında tamamen bozulmasının ve daha büyük bir arızaya yol açmasının önüne geçilmiştir. Bu senaryo, SCADA ve yapay zekâ tabanlı kestirimci bakım sistemlerinin gerçek zamanlı müdahale kabiliyetini ve uçuş emniyetine olan katkısını doğrudan göstermektedir.

6.5. Literatürdeki Uygulama Örnekleri

Literatürde SCADA ve yapay zekâ destekli kestirimci bakım uygulamalarının uçak motorları ve fren sistemleri gibi kritik bileşenlerde arızaları önceden tespit etmede etkin olduğu birçok çalışma ile desteklenmektedir. Örneğin, Zonta ve diğerleri (2020) tarafından yapılan sistematik incelemelerde, SCADA sensör verileri ile PdM algoritmalarının entegre edilmesinin plansız duruş sürelerini azaltmada etkin bir biçimde kullanıldığı vurgulanmıştır (Zonta ve diğerleri, 2020). Ayrıca Civerchia ve diğerleri (2017), SCADA tabanlı sistemlerin sıcaklık ve titreşim verilerini analiz ederek arızaların erken tespitine katkı sağladığını göstermiştir (Civerchia ve diğerleri, 2017). Bunun ötesinde, başka sektörlerde yapılan vaka analizleri de bu yaklaşımların bakım planlamasını güçlendirdiğini ortaya koymakta, sistem sürekliliği ve operasyonel verimlilik açısından faydaları desteklemektedir (Pech ve diğerleri, 2021).

Yıldırım ve Rana (2024), SCADA benzeri sensör verileriyle LSTM tabanlı bir sağlık izleme framework'ü geliştirerek uçağın motor sağlığını gerçek zamanlı olarak değerlendirmiştir. Çalışma, en yüksek sınıflandırma doğruluğunu (yaklaşık %98.9) elde etmiş ve RUL tahmininde ortalama mutlak hata değerini (~1.28) göstermiştir, bu da havacılıkta kestirimci bakım uygulamalarındaki doğruluğu ve güvenilirliği destekleyen güçlü bir kanıt sunmaktadır.

6.6. SCADA-PdM Entegrasyonunun Avantajları

SCADA ile kestirimci bakım entegrasyonunun başlıca avantajları aşağıdaki gibidir.

- Arıza öncesi erken uyarı sistemi sağlar.
- Bakım faaliyetlerini daha verimli planlar.
- Yedek parça tüketimini optimize eder.
- İnsan hatalarını azaltır.
- Havacılıkta AOG riskini düşürerek operasyonel sürekliliği destekler.

6.7. Sınırlılıklar ve Geliştirme Alanları

SCADA ile kestirimci bakım entegrasyonunun bazı sınırlı olduğu ve dezavantajları aşağıda belirtilmiştir.

- AI modellerinin eğitimi için yüksek kaliteli veriye ihtiyaç vardır.
- SCADA sistemleri siber tehditlere açıktır.
- Farklı uçak modelleri için algoritmaların yeniden eğitilmesi gerekebilir.
- Sensörlerin kalibrasyon hataları analiz doğruluğunu etkileyebilir.

Sonuç olarak, SCADA ile PdM sistemlerinin entegrasyonu, uçak bakım süreçlerinde devrim niteliğinde bir dijital dönüşüm sağlamaktadır. Bu entegrasyon sayesinde bakım süreçleri sadece izleyici değil, aynı zamanda öğrenen ve öngören sistemler haline gelmiştir.

6.8. SCADA Tabanlı Kestirimci Bakım Sisteminin Çalışma Prensipleri

SCADA tabanlı kestirimci bakım sistemleri, uçak üzerinde bulunan sensörlerden alınan verileri gerçek zamanlı olarak toplamakta ve bu verileri analiz ederek potansiyel arıza durumlarını önceden belirlemektedir. Bu sistemlerin temel prensibi, verilerin sürekli olarak izlenmesi ve erken uyarı mekanizmalarının etkin biçimde sağlanmasıdır.

6.9. SCADA Üzerinden Veri Toplama ve İzleme Yöntemleri

SCADA sistemleri, uçaktaki motor, hidrolik sistemler, elektrik ve elektronik bileşenlerden sürekli veri akışı sağlar. Toplanan veriler, sıcaklık, basınç, titreşim gibi parametrelerden oluşabilir. Bu veriler, SCADA sunucularına aktararak merkezî kontrol ve izleme odalarından gerçek zamanlı takip edilir. Verilerin sürekli olarak izlenmesi, anormal durumların hızlı bir şekilde tespit edilmesini mümkün kılar. <

6.10. Toplanan Verilerin Analizi ve Arıza Tahminleme Algoritmaları

SCADA sistemlerinden elde edilen veriler, çeşitli veri analizi yöntemleri ve algoritmalar ile değerlendirilir. Bu analizlerde, istatistiksel yöntemler, spektral analiz, trend analizleri ve makine öğrenmesi teknikleri kullanılmaktadır. Özellikle makine öğrenmesi algoritmaları, büyük veri kümelerindeki desenleri tanımlayarak arıza durumlarının erken aşamada tespit edilmesini sağlar.

6.11. SCADA Sistemleri ile Uçak Sistemleri Entegrasyonu

SCADA sistemlerinin uçak bakım süreçlerinde etkin olarak kullanılabilmesi için uçaktaki mevcut aviyonik sistemler ve sensörlerle yüksek düzeyde entegrasyon sağlanması gerekmektedir. Bu entegrasyon sayesinde veri akışı kesintisiz ve hatasız gerçekleşir. Sistem entegrasyonu ayrıca, veri iletişim protokollerinin uyumluluğu ve güvenliği açısından da kritik öneme sahiptir.

6.12. SCADA Kullanılarak Yapılan Kestirimci Bakım Uygulamalarına Örnekler

SCADA tabanlı kestirimci bakım uygulamaları dünya çapında birçok havayolu ve uçak üreticisi tarafından başarıyla uygulanmaktadır. Örneğin, motor performans takibi ve erken arıza tahminleme sistemleri, SCADA temelli veri izleme ve analiz süreçleri ile gerçekleştirilmekte olup, bu uygulamalar bakım maliyetlerini azaltmış ve uçuş güvenliğini artırmıştır. Benzer şekilde hidrolik sistemlerdeki olası arıza belirtileri ve aviyonik sistemlerde meydana gelebilecek arızalar da SCADA sistemleri sayesinde erken aşamada teşhis edilebilmektedir.

7. SONUÇLAR VE ÖNERİLER

7.1. SCADA ile Kestirimci Bakımın Avantajları ve Sağladığı Katkıları

SCADA sistemlerinin kestirimci bakım stratejileriyle entegre çalışması, havacılık sektörü için önemli faydalar sağlamaktadır. Bu faydalar yalnızca operasyonel verimlilik değil, aynı zamanda uçuş emniyeti, bakım maliyetleri ve sistem performansı gibi çok sayıda alanı kapsamaktadır.

- **Erken Uyarı Mekanizmaları:** SCADA sistemleri sensörler aracılığıyla elde edilen verileri anlık olarak analiz ederek, arıza oluşmadan önce müdahale edilmesini sağlar. Bu, uçuş güvenliğini artırır ve ciddi arızaların önüne geçer.
- **Maliyet Tasarrufu:** Önceden planlanan ve yalnızca ihtiyaç halinde gerçekleştirilen bakım işlemleri, hem iş gücünden hem de yedek parça kullanımından tasarruf sağlar.
- **Operasyonel Süreklilik:** AOG (Aircraft on Ground) durumları azaltılarak uçakların aktif hizmet süresi artırılır.
- **Veri Tabanlı Karar Verme:** Toplanan geçmiş veriler ile geleceğe yönelik daha isabetli ve güvenilir kararlar alınabilir.
- **Kaynak Yönetimi:** İnsan, zaman ve ekipman kaynaklarının daha etkin planlanmasını sağlar.

7.2. SCADA ile Kestirimci Bakımın Sınırlılıkları

Her ne kadar çok sayıda avantaj sunsa da, SCADA tabanlı kestirimci bakım uygulamalarının bazı sınırlılıkları ve zorlukları mevcuttur:

- **Yüksek İlk Yatırım Maliyeti:** SCADA altyapısı, sensör ağı, yazılım ve entegrasyon çalışmaları büyük yatırımlar gerektirebilir.
- **Siber Güvenlik Riskleri:** SCADA sistemleri, siber saldırılara karşı hassas yapıdadır. Özellikle kritik uçak sistemlerine bağlı SCADA uygulamaları yüksek güvenlik önlemleri gerektirir.
- **Veri Kalitesi ve Erişilebilirliği:** Sağlıklı analizler için yüksek kaliteli, sürekli ve tutarlı verilere ihtiyaç vardır. Sensör arızaları, kalibrasyon hataları analiz doğruluğunu olumsuz etkileyebilir.

- **Uzmanlık Gereksinimi:** SCADA ve kestirimci bakım sistemlerinin etkili kullanımı için teknik personelin ileri düzeyde eğitimli olması gerekir.
- **Yazılım Uyumsuzlukları:** Farklı sistemlerin (örneğin eski uçaklar ile modern SCADA altyapıları) entegrasyonu zor ve zaman alıcı olabilir.

7.3. Gelecekte SCADA-Kestirimci Bakım Sistemlerinin Evrimi

Havacılık sektöründe dijital dönüşüm süreci ile birlikte SCADA sistemlerinin rolü daha da büyümektedir. Özellikle yapay zekâ, büyük veri, IoT ve dijital ikiz teknolojilerinin gelişmesiyle birlikte kestirimci bakım sistemlerinin çok daha öngörülü ve otonom hale gelmesi beklenmektedir.

- **Yapay Zekâ Destekli Tahminleme:** Geçmiş verilerden öğrenen AI sistemleri sayesinde arıza tahmini daha isabetli hale gelecek.
- **Dijital İkiz (Digital Twin):** Gerçek uçak sistemlerinin dijital kopyaları üzerinden simülasyonlar yapılarak bakım stratejileri test edilebilecek.
- **Otonom Bakım Sistemleri:** Uçak, kendi üzerindeki sensörlerden gelen verilerle arıza ihtimalini tespit ederek bakım talebi oluşturabilecek.
- **IoT Tabanlı Entegre Sistemler:** Uçak, bakım merkezi, parça tedarikçisi ve üretici firma arasında gerçek zamanlı bağlantı kurularak entegre bakım süreçleri geliştirilecek.
- **Blockchain ile Veri Güvenliği:** Bakım geçmişi, parça değişim kayıtları gibi verilerin doğruluğu ve güvenliği blockchain altyapısıyla sağlanabilecek.

Geleneksel SCADA mimarileri, son yıllarda IoT teknolojileriyle entegre edilerek daha esnek, veri odaklı ve kestirimci bakım uygulamalarına uygun bir yapıya kavuşmuştur. Bu dönüşüm sayesinde bakım faaliyetlerinde hem gerçek zamanlı izleme hem de önleyici müdahaleler mümkün hâle gelmektedir.

Endüstri 4.0 ile birlikte üretim sistemlerinde dijitalleşme, akıllı sensörler, büyük veri analitiği ve otomasyon sistemlerinin entegrasyonu büyük önem kazanmıştır. Kang ve diğerleri (2016), akıllı üretim kavramını geçmişten günümüze kapsamlı biçimde değerlendirerek, gelecekte SCADA benzeri sistemlerin daha esnek, öğrenebilen ve kestirimci yapılarla evrileceğini vurgulamaktadır.

7.4. Literatür Perspektifi

Literatürde, SCADA sistemleri ve IoT/dijital ikiz teknolojilerinin entegrasyonu ile kestirimci bakım uygulamalarında daha güvenilir veri izleme, erken arıza uyarısı ve bakım süreçlerinin öngörülebilirliğinin arttığı vurgulanmaktadır (Lee ve diğerleri, 2015; Zonta ve diğerleri, 2020; Civerchia ve diğerleri, 2017).

7.5. SCADA Sistemlerinin Güvenlik Boyutu ve Regülasyonlar

Havacılık bakım süreçlerinde kullanılan SCADA sistemleri, yüksek düzeyde otomasyon ve veri erişimi sağlamakla birlikte, siber güvenlik açısından da çeşitli tehditlere açık hâle gelmektedir. Bu sistemler üzerinden gerçek zamanlı olarak iletilen verilerin doğruluğu ve gizliliği, uçuş güvenliğini doğrudan etkileme potansiyeline sahiptir. Bu nedenle, SCADA sistemlerinin yalnızca işlevsellik açısından değil, bilgi güvenliği açısından da tasarlanması ve yönetilmesi gerekmektedir.

SCADA sistemleri genellikle endüstriyel kontrol sistemleri (ICS) kategorisine girer ve özel protokollerle çalışır. Ancak bu protokoller genellikle şifrelenmemiş veri iletimi yapar. Bu da yetkisiz erişim, veri manipülasyonu, kimlik sahtekârlığı gibi saldırılara zemin hazırlayabilir. Özellikle uçak bakım süreçlerinde SCADA sistemi aracılığıyla aktarılan sensör verileri, arıza uyarıları ve bakım kararları, saldırganlar tarafından ele geçirilirse kritik sonuçlar doğabilir.

SCADA sistemlerinin güvenliğini sağlamak için aşağıdaki önlemler alınmalıdır:

- Ağ segmentasyonu yapılmalı, SCADA ağı kurumsal ağdan fiziksel olarak ayrılmalıdır.
- Veriler şifreli protokollerle iletmeli (ör. TLS, VPN).
- Tüm erişimler kimlik doğrulamalı ve kayıt altına alınmalıdır.
- Anomali tespiti için güvenlik duvarları ve saldırı tespit sistemleri kullanılmalıdır.
- Günlük (log) analizleri ve zaman damgalı veri kayıtları tutulmalıdır.

Ayrıca, havacılıkta bakım süreçlerinde kullanılan SCADA sistemleri için ISO/IEC 27001 ve IEC 62443 gibi uluslararası bilgi güvenliği standartlarına uyum zorunluluğu giderek yaygınlaşmaktadır. Bu standartlar, SCADA sistemlerinin hem yazılım hem donanım bileşenlerinin güvenliğini kapsayan bir çerçeve sunmaktadır.

SCADA sistemlerinin güvenliğini sağlamak, kestirimci bakım verilerinin bütünlüğünü ve sürekliliğini korumak açısından kritik önemdedir. Patel ve diğerleri (2009), SCADA iletişim ağlarında siber güvenliği artırmaya yönelik protokollerin, bakım süreçlerinde veri güvenliğini sağladığını belirtmiştir.

Pech, Vrchota ve Bednář (2021), akıllı fabrikalarda kullanılan kestirimci bakım sistemlerinde akıllı sensörlerin veri toplama ve durum izleme açısından oynadığı kritik rolü vurgulamış ve bu teknolojilerin sistem güvenilirliğini artırmada etkin olduğunu göstermiştir.

SCADA sistemlerinin siber-fiziksel yapısı, yalnızca izleme ve kontrol işlevlerinin entegrasyonunu değil, aynı zamanda veri güvenliği ve saldırı tespit mekanizmalarını da içermelidir. Sheng ve diğerleri (2021), SCADA sistemleri için geliştirdikleri siber-fiziksel model ile potansiyel tehditleri tespit edebilen bir yapı sunmuş; özellikle bu tür sistemlerde veri bütünlüğü ve operatör güvenliğinin sağlanmasının kritik önem taşıdığını vurgulamışlardır.

Yağcı (2020), SCADA sistemlerinde güvenliğin sağlanması amacıyla saldırı yüzeylerini minimize eden ve erişim kontrolünü esas alan bütüncül bir model önermiştir.

Grilo ve diğerleri (2014), kritik altyapıların izlenmesinde WSN ve SCADA'nın entegre kullanımını önererek, dağıtık yapıli sistemlerde gerçek zamanlı veri toplama ve kestirimci analizlerin güvenilir biçimde uygulanabileceğini göstermiştir.

Sonuç olarak, SCADA tabanlı kestirimci bakım sistemlerinin güvenliği sadece veri bütünlüğü açısından değil, uçuş güvenliği açısından da hayati önem taşımaktadır. Bu nedenle bakım kuruluşlarının, dijital altyapılarını yalnızca verimli değil, aynı zamanda güvenli olacak şekilde planlamaları gerekmektedir.

7.6. Genel Değerlendirme

SCADA tabanlı kestirimci bakım sistemleri, havacılık sektörünün artan emniyet, maliyet kontrolü ve dijitalleşme hedeflerine doğrudan hizmet etmektedir. Avantajları yüksek olmasına rağmen, sistemin etkili şekilde kurulması ve sürdürülebilirliği için teknolojik altyapı, uzmanlık ve güvenlik önlemleri gibi faktörlerin sağlanması kritik öneme sahiptir.

Gelecekte, bu sistemlerin sadece bakım süreçlerini değil; uçuş planlaması, filo yönetimi ve havayolu performans yönetimi gibi daha geniş operasyonel alanlara yayılması öngörülmektedir.

7.7. Araştırmadan Elde Edilen Genel Sonuçlar

Bu tez çalışması, havacılık sektöründe uçak bakım süreçlerinde SCADA tabanlı kestirimci bakım analizinin etkinliğini incelemektedir. Yapılan analizler ve literatür taramaları doğrultusunda aşağıdaki sonuçlara ulaşılmıştır:

- Kestirimci bakımın uçak bakım süreçlerine entegrasyonu, işletme operasyonlarının verimliliğini artırarak öngörülemeyen arızaları ve bakım maliyetlerini azaltmaktadır. Bu durum, havayolu şirketleri için ciddi ekonomik avantajlar sunmaktadır.
- SCADA sistemleri, havacılık bakım süreçlerinde merkezi bir izleme ve kontrol altyapısı sağlayarak gerçek zamanlı veri toplama ve analiz yapma olanağı sunmaktadır. Bu sayede, uçak bileşenlerinin performansı sürekli olarak izlenebilmekte ve kritik durumlar önceden tespit edilebilmektedir.
- Yapay zekâ ve büyük veri analitiği ile desteklenen kestirimci bakım uygulamaları, havacılık sektöründe hata tespiti ve bakım planlamasında önemli iyileştirmeler sağlamaktadır. SCADA sistemleri, tahmine dayalı modeller oluşturarak mühendislerin erken müdahale etmesini sağlamaktadır.
- SCADA tabanlı kestirimci bakım uygulamalarının en büyük zorluklarından biri, yüksek yatırım maliyetleri ve sistem entegrasyonunun karmaşıklığıdır. Küçük ölçekli havacılık işletmeleri için SCADA sistemlerinin benimsenmesi maliyet açısından sınırlayıcı olabilmektedir.
- SCADA sistemlerinde siber güvenlik açıkları, havacılık bakım süreçleri için büyük bir risk oluşturmaktadır. SCADA sistemleri, uçak bakım süreçlerinde büyük miktarda hassas veri işlemekte olup, bu sistemlerin siber saldırılara karşı güvenliğinin sağlanması kritik önem taşımaktadır.

7.8. Öneriler ve Gelecekte Yapılabilecek Çalışmalar

SCADA tabanlı kestirimci bakım sistemlerinin havacılık sektöründe daha etkin hale gelmesi için aşağıdaki öneriler sunulmaktadır:

- Daha güçlü siber güvenlik önlemleri geliştirilmelidir. SCADA sistemleri, uçak bakım süreçlerinde büyük veri hacmi işlediğinden, siber saldırılara karşı daha güçlü güvenlik protokolleri uygulanmalıdır. Güvenli iletişim protokolleri (örneğin

TLS/SSL), ağ güvenlik duvarları ve düzenli güvenlik testleri, veri güvenliğini sağlamak için kullanılmalıdır.

- SCADA sistemleri ile yapay zekâ destekli kestirimci bakım modellerinin entegrasyonu artırılmalıdır. Makine öğrenmesi ve büyük veri analiz yöntemleri, uçak bileşenlerinden gelen verileri daha doğru analiz ederek bakım süreçlerini optimize edebilir.
- Dijital ikiz teknolojisinin SCADA ile entegrasyonu araştırılmalıdır. Dijital ikiz modelleri, uçak bileşenlerinin sanal simülasyonlarını oluşturarak bakım süreçlerini daha öngörülebilir hale getirebilir. Bu sayede, bakım mühendisleri olası arızaları önceden tespit edebilir.
- SCADA sistemlerinin maliyet-etkin çözümleri geliştirilmelidir. Özellikle küçük ölçekli havayolu şirketleri için SCADA tabanlı kestirimci bakım çözümlerinin ekonomik hale getirilmesi, sektörde daha yaygın kullanılmasını sağlayacaktır.
- Havacılık sektöründe SCADA tabanlı kestirimci bakım uygulamalarına yönelik daha fazla akademik ve endüstriyel araştırma yapılmalıdır. Uygulamalı çalışmalar ve çok paydaşlı iş birlikleri sayesinde, SCADA teknolojisinin uçak bakım süreçlerinde daha etkin kullanılabilmesi için, çeşitli hava yollarında saha çalışmaları ve pilot uygulamalar gerçekleştirilmelidir.

Sonuç olarak, SCADA tabanlı kestirimci bakım sistemleri, havacılık sektöründe bakım süreçlerini optimize ederek hem operasyonel güvenliği hem de ekonomik sürdürülebilirliği artırmaktadır. Bu alanda yapılacak yeni çalışmalar ve teknolojik ilerlemeler, gelecekte havacılık bakım süreçlerinin daha verimli, güvenli ve maliyet etkin olmasını sağlayacaktır.

KAYNAKÇA

- Abdar, M., Pourpanah, F., Hussain, S., Rezazadegan, D., Liu, L., Ghavamzadeh, M., ... and Nahavandi, S. (2021). A review of uncertainty quantification in deep learning: Techniques, applications and challenges. *Information fusion*, 76, 243-297.
- Ahmad, A. S., Hassan, M. Y., Abdullah, M. P., Rahman, H. A., Hussin, F., Abdullah, H., and Saidur, R. (2014). A review on applications of ANN and SVM for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102-109.
- Aliyev, P. LSTM ve GRU Modellerinde Açıklanabilir Yapay Zekâ Yaklaşımı: İktisadi Veriler Üzerine Bir Uygulama. *Journal of the Institute of Science and Technology*, 15(2), 396-411.
- Arena, S., Florian, E., Sgarbossa, F., Sølvsberg, E., and Zennaro, I. (2024). A conceptual framework for machine learning algorithm selection for predictive maintenance. *Engineering Applications of Artificial Intelligence*, 133, 108340.
- Arslan, S. (2010). Titreşim analizi ile fanlarda arıza teşhisi ve kestirimci bakım (Doctoral dissertation, Yüksek Lisans Tezi, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Zonguldak).
- Asubay, M. B. (2018). SCADA sistemlerinin tanıtımı ve kullanılan haberleşme protokolleri. Bitlis Eren Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Atasoy, B., ve Kurşun, S. (2023). Kaotik zaman serilerinin kestirimci bakım temelli aktif arızaya dayanıklı kontrol sistemleri için uygulanması. In *Otomatik Kontrol Ulusal Toplantısı (TOK 2023)*, İstanbul, Türkiye.
- Aydin, O., and Guldamlasioglu, S. (2017, April). Using LSTM networks to predict engine condition on large scale data processing framework. In *2017 4th International Conference on Electrical and Electronic Engineering (ICEEE)* (pp. 281-285). IEEE.
- AYLAK, B., ORAL, O., and YAZICI, K. (2021). Using artificial intelligence and machine learning applications in logistics Yapay zeka ve makine öğrenmesi tekniklerinin lojistik sektöründe kullanımı. *El-Cezeri Journal of Science and Engineering*, 8(1).
- Bampoula, X., Siaterlis, G., Nikolakis, N., and Alexopoulos, K. (2021). A deep learning model for predictive maintenance in cyber-physical production systems using lstm autoencoders. *Sensors*, 21(3), 972.
- Bansal, D., Evans, D. J., and Jones, B. (2004). A real-time predictive maintenance system for machine systems. *International Journal of Machine tools and manufacture*, 44(7-8), 759-766.
- Batur, C., Zhou, L., and Chan, C. C. (2002, December). Support vector machines for fault detection. In *Proceedings of the 41st IEEE Conference on Decision and Control*, 2002. (Vol. 2, pp. 1355-1356). IEEE.
- Bayındır, R., Kaplan, O., Bayyigit, C., Sarıkaya, Y., ve Hallaçlıoğlu, M. (2011). PLC ve SCADA kullanılarak bir endüstriyel sistemin otomasyonu. *Erciyes Üniversitesi*
- Boyer, S. (1999). SCADA: SUPERVISORY CONTROL AND DATA ACQ.

- Bruneo, D., and De Vita, F. (2019, June). On the use of LSTM networks for predictive maintenance in smart industries. In 2019 IEEE International Conference on Smart Computing (SmartComp) (pp. 241-248). IEEE.
- Cardoso, D., and Ferreira, L. (2020). Application of predictive maintenance concepts using artificial intelligence tools. *Applied Sciences*, 11(1), 18.
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., and Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers and Industrial Engineering*, 137, 106024.
- Chang, C. C., and Lin, C. J. (2011). LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 1-27.
- Chhajer, P., Shah, M., and Kshirsagar, A. (2022). The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction. *Decision Analytics Journal*, 2, 100015.
- Chicco, D., and Jurman, G. (2020). Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone. *BMC medical informatics and decision making*, 20(1), 16.
- Chu, C., Proth, J. M., and Wolff, P. (1998). Predictive maintenance: The one-unit replacement model. *International Journal of Production Economics*, 54(3), 285-295.
- Civerchia, F., Bocchino, S., Salvadori, C., Rossi, E., Maggiani, L., and Petracca, M. (2017). Industrial Internet of Things monitoring solution for advanced predictive maintenance applications. *Journal of Industrial Information Integration*, 7, 4-12.
- Clarke, G., Reynders, D., and Wright, E. (2004). Practical modern SCADA protocols: DNP3, 60870.5 and related systems. Newnes.
- Colombo, A. W., Karnouskos, S., and Bangemann, T. (2014). Towards the next generation of industrial cyber-physical systems. In *Industrial cloud-based cyber-physical systems: The IMC-AESOP Approach* (pp. 1-22). Cham: Springer International Publishing.
- Dalzochio, J., Kunst, R., Pignaton, E., Binotto, A., Sanyal, S., Favilla, J., and Barbosa, J. (2020). Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in industry*, 123, 103298.
- Daneels, A., and Salter, W. (1999). What is SCADA?.
- Davari, N., Veloso, B., Costa, G. D. A., Pereira, P. M., Ribeiro, R. P., and Gama, J. (2021). A survey on data-driven predictive maintenance for the railway industry. *Sensors*, 21(17), 5739.
- Dos Santos, T., Ferreira, F. J., Pires, J. M., and Damasio, C. (2017, May). Stator winding short-circuit fault diagnosis in induction motors using random forest. In 2017 IEEE International Electric Machines and Drives Conference (IEMDC) (pp. 1-8). IEEE.
- Du, W., Zhang, J., Meng, G., and Zhang, H. (2024). Aero-Engine Fault Detection with an LSTM Auto-Encoder Combined with a Self-Attention Mechanism. *Machines*, 12(12), 879.

- Eriksson, J. (2020). Machine learning for predictive maintenance on wind turbines: Using SCADA data and the Apache Hadoop ecosystem.
- European Union Aviation Safety Agency (EASA). (2020). *Part-145 regulation and digital maintenance implementation*. Cologne, Germany: EASA Publications.
- Federal Aviation Administration (FAA). (2021). *Advisory circular 43-210: Predictive maintenance approaches*. Washington, DC: U.S. Department of Transportation.
- Gao, J., Liu, J., Rajan, B., Nori, R., Fu, B., Xiao, Y., ... and Philip Chen, C. L. (2014). SCADA communication and security issues. *Security and Communication Networks*, 7(1), 175-194.
- Gilabert, E., Fernandez, S., Arnaiz, A., and Konde, E. (2017). Simulation of predictive maintenance strategies for cost-effectiveness analysis. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 231(13), 2242-2250.
- Grosse, C. U., Ohtsu, M., Aggelis, D. G., and Shiotani, T. (Eds.). (2021). *Acoustic emission testing: Basics for research–applications in engineering*. Springer Nature.
- Goldman, S. M., Fiedler, E. R., and King, R. E. (2002). General aviation maintenance-related accidents: A review of ten years of NTSB Data.
- Grilo, A. M., Chen, J., Diaz, M., Garrido, D., and Casaca, A. (2014). An integrated WSN and SCADA system for monitoring a critical infrastructure. *IEEE Transactions on Industrial Informatics*, 10(3), 1755-1764.
- Huang, R., Wei, C., Wang, B., Yang, J., Xu, X., Wu, S., and Huang, S. (2022). Well performance prediction based on Long Short-Term Memory (LSTM) neural network. *Journal of Petroleum Science and Engineering*, 208, 109686.
- INCOSE. (2024). System-based predictive maintenance for aerospace applications. *Systems Engineering*, 27(1), 17–29.
- International Civil Aviation Organization (ICAO). (2018). *Manual of aircraft maintenance management*. Montreal, Canada: ICAO.
- İşbilen, F., ve Konar, M. (2020). Uçak sistemlerinin SCADA ile modellenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (18), 338-346.
- Jack, L. B., and Nandi, A. K. (2002). Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms. *Mechanical systems and signal processing*, 16(2-3), 373-390.
- Jeff, D. (2005). Supervisory control and data acquisition (SCADA) introduction. USA: Pacific Northwest National Laboratory, Grainger Lecture Series for the University of Illinois at Urbana-Champaign.
- Jiang, Y., Dai, P., Fang, P., Zhong, R. Y., Zhao, X., and Cao, X. (2022). A2-LSTM for predictive maintenance of industrial equipment based on machine learning. *Computers and Industrial Engineering*, 172, 108560.
- Joshi, P. (2017). *Artificial intelligence with python*. Packt Publishing Ltd..
- Kang, H. S., Lee, J. Y., Choi, S., Kim, H., Park, J. H., Son, J. Y., ... and Noh, S. D. (2016). Smart manufacturing: Past research, present findings, and future

- directions. *International journal of precision engineering and manufacturing-green technology*, 3(1), 111-128.
- Karaçor, M., ve Keleş, K. (2007). Otomasyon sistemlerinin bileşenleri. VI. Otomasyon Sempozyumu, Samsun.
- Karadayı, H. M. (2011). Titreşim analizi ile pompalarda arıza tespiti ve kestirimci bakım uygulamaları (Master's thesis, Balıkesir University (Turkey)).
- Karmiani, D., Kazi, R., Nambisan, A., Shah, A., and Kamble, V. (2019, February). Comparison of predictive algorithms: backpropagation, SVM, LSTM and Kalman Filter for stock market. In 2019 amity international conference on artificial intelligence (AICAI) (pp. 228-234). IEEE.
- Kaynak, G. (2022). Kestirimci bakım planlaması için zaman serisi modellerine dayalı arıza zamanı tahmini.
- Keleko, A. T., Kamsu-Foguem, B., Ngouna, R. H., and Tongne, A. (2022). Artificial intelligence and real-time predictive maintenance in industry 4.0: a bibliometric analysis. *AI and Ethics*, 2(4), 553-577.
- Kiangala, K. S., and Wang, Z. (2018). Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts. *The International Journal of Advanced Manufacturing Technology*, 97(9), 3251-3271.
- Kim, D. G., and Choi, J. Y. (2021). Optimization of design parameters in LSTM model for predictive maintenance. *Applied Sciences*, 11(14), 6450.
- Kinnison, H. A., and Siddiqui, T. (2013). Aviation maintenance management.
- Kurani, A., Doshi, P., Vakharia, A., and Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), 183-208.
- Lee, J., Bagheri, B., and Kao, H. A. (2015). A cyber-physical systems architecture for industry 4.0-based manufacturing systems. *Manufacturing letters*, 3, 18-23.
- Lee, J., Davari, H., Singh, J., and Pandhare, V. (2018). Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manufacturing letters*, 18, 20-23.
- Lee, W. J., Wu, H., Yun, H., Kim, H., Jun, M. B., and Sutherland, J. W. (2019). Predictive maintenance of machine tool systems using artificial intelligence techniques applied to machine condition data. *Procedia Cirp*, 80, 506-511.
- Liu, J., Lei, F., Pan, C., Hu, D., and Zuo, H. (2021). Prediction of remaining useful life of multi-stage aero-engine based on clustering and LSTM fusion. *Reliability Engineering and System Safety*, 214, 107807.
- Liu, Z., Jia, Z., Vong, C. M., Bu, S., Han, J., and Tang, X. (2017). Capturing high-discriminative fault features for electronics-rich analog system via deep learning. *IEEE Transactions on Industrial Informatics*, 13(3), 1213-1226.
- Malhotra, P., Vig, L., Shroff, G., and Agarwal, P. (2015, April). Long short term memory networks for anomaly detection in time series. In *Proceedings* (Vol. 89, No. 9, p. 94).

- Marais, K. B., and Robichaud, M. R. (2012). Analysis of trends in aviation maintenance risk: An empirical approach. *Reliability Engineering and System Safety*, 106, 104-118.
- Meyer, A. (2021, September). Early fault detection with multi-target neural networks. In *International Conference on Computational Science and Its Applications* (pp. 429-437). Cham: Springer International Publishing.
- Mobley, R. K. (2002). *An introduction to predictive maintenance*. Elsevier.
- Mofokeng, T., Mativenga, P. T., and Marnewick, A. (2020). Analysis of aircraft maintenance processes and cost. *Procedia CIRP*, 90, 467-472..
- Nagpal, A., and Gabrani, G. (2019, February). Python for data analytics, scientific and technical applications. In *2019 Amity international conference on artificial intelligence (AICAI)* (pp. 140-145). IEEE.
- Orhan, S. (2002). Rulmanlarla yataklanmış dinamik sistemlerin titreşim analiziyle kestirimci bakımı. *Fen Bilimleri Enstitüsü, Makine Ana Bilim Dalı, Kırıkkale*, 161.
- Özer, A. (2009). *Van ili kablosuz haberleşme teknolojisi kullanılarak enerji otomasyonunun sağlanması* (Yüksek lisans tezi). Yüzüncü Yıl Üniversitesi, Fen Bilimleri Enstitüsü, Van.
- Paolanti, M., Romeo, L., Felicetti, A., Mancini, A., Frontoni, E., and Loncarski, J. (2018, July). Machine learning approach for predictive maintenance in industry 4.0. In *2018 14th IEEE/ASME international conference on mechatronic and embedded systems and applications (MESA)* (pp. 1-6). IEEE..
- Patel, S. C. (2006). *Secure internet-based communication protocol for SCADA networks*. University of Louisville..
- Patel, S. C., Bhatt, G. D., and Graham, J. H. (2009). Improving the cyber security of SCADA communication networks. *Communications of the ACM*, 52(7), 139-142..
- Pech, M., Vrchota, J., and Bednář, J. (2021). Predictive maintenance and intelligent sensors in smart factory. *Sensors*, 21(4), 1470..
- Plumb, A. P., Rowe, R. C., York, P., and Brown, M. (2005). Optimisation of the predictive ability of artificial neural network (ANN) models: a comparison of three ANN programs and four classes of training algorithm. *European Journal of Pharmaceutical Sciences*, 25(4-5), 395-405.
- Qassim, Q. S., Ali, M. A., and Tahir, N. M. (2023, August). Security analysis of dnp3 protocol in scada system. In *2023 IEEE 13th International Conference on Control System, Computing and Engineering (ICCSCE)* (pp. 314-319). IEEE.
- Rajesh, M., and Vikrant, V. (2016). *PLCs and SCADA Theory and Practice*.
- Randall, R. B., and Antoni, J. (2011). Rolling element bearing diagnostics—A tutorial. *Mechanical systems and signal processing*, 25(2), 485-520.
- Randall, R. B. (2011). *Vibration-based condition monitoring: industrial, aerospace and automotive applications* John Wiley and Sons [Google Scholar].

- Raschka, S., Patterson, J., and Nolet, C. (2020). Machine learning in python: Main developments and technology trends in data science, machine learning, and artificial intelligence. *Information*, 11(4), 193.
- Rodriguez, P. C., Marti-Puig, P., Caiafa, C. F., Serra-Serra, M., Cusidó, J., and Solé-Casals, J. (2023). Exploratory analysis of SCADA data from wind turbines using the K-means clustering algorithm for predictive maintenance purposes. *Machines*, 11(2), 270.
- Saito, T., and Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PloS one*, 10(3), e0118432.
- Saxena, A., Goebel, K., Simon, D., and Eklund, N. (2008, October). Damage propagation modeling for aircraft engine run-to-failure simulation. In 2008 international conference on prognostics and health management (pp. 1-9). IEEE.
- Scaife, A. D. (2024). Improve predictive maintenance through the application of artificial intelligence: A systematic review. *Results in Engineering*, 21, 101645.
- Serradilla, O., Zugasti, E., Rodriguez, J., and Zurutuza, U. (2022). Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects. *Applied Intelligence*, 52(10), 10934-10964.
- Sheng, C., Yao, Y., Fu, Q., and Yang, W. (2021). A cyber-physical model for SCADA system and its intrusion detection. *Computer Networks*, 185, 107677.
- Sideratos, G., and Hatziargyriou, N. D. (2007). An advanced statistical method for wind power forecasting. *IEEE Transactions on power systems*, 22(1), 258-265.
- Sujon, K. M., Hassan, R. B., Towshi, Z. T., Othman, M. A., Samad, M. A., and Choi, K. (2024). When to use standardization and normalization: empirical evidence from machine learning models and XAI. *IEEE access*.
- Surucu, O., Gadsden, S. A., and Yawney, J. (2023). Condition monitoring using machine learning: A review of theory, applications, and recent advances. *Expert Systems with Applications*, 221, 119738.
- Suryadarma, E. H. E., and Ai, T. J. (2020). Predictive Maintenance in SCADA-Based Industries: A literature review. *International Journal of Industrial Engineering and Engineering Management*, 2(1), 57-70.
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S., and Beghi, A. (2014). Machine learning for predictive maintenance: A multiple classifier approach. *IEEE transactions on industrial informatics*, 11(3), 812-820.
- Şahin, C., Bolat, E., and Karaçor, M. (2012). Development of OPC Based SCADA System Using SIEMENS CPU 224 for Educational Purposes. *Technological Applied Sciences*, 7(2), 17-27.
- Teixeira, M. A., Salman, T., Zolanvari, M., Jain, R., Meskin, N., and Samaka, M. (2018). SCADA system testbed for cybersecurity research using machine learning approach. *Future Internet*, 10(8), 76.
- Teoh, T. T., and Rong, Z. (2022). Artificial intelligence with python (pp. 3-328). Berlin, Germany: Springer.

- TTS Integrated Training System. (2011). Module 13: Aircraft aerodynamics, structures and systems for EASA Part-66 licence category A, B1 and B2. TTS Integrated Training System.
- Ucar, A., Karakose, M., and Kırımça, N. (2024). Artificial intelligence for predictive maintenance applications: key components, trustworthiness, and future trends. *Applied Sciences*, 14(2), 898.
- Udo, W., and Muhammad, Y. (2021). Data-driven predictive maintenance of wind turbine based on SCADA data. *IEEE Access*, 9, 162370-162388.
- Usamentiaga, R., Venegas, P., Guerediaga, J., Vega, L., Molleda, J., and Bulnes, F. G. (2014). Infrared thermography for temperature measurement and non-destructive testing. *Sensors*, 14(7), 12305-12348.
- Van den Bergh, J., De Bruecker, P., Beliën, J., and Peeters, J. (2013). Aircraft maintenance operations: state of the art. HUB Research Paper 2013/09.
- Volkan, A. K., and İNNER, Ö. Ü. A. B. TURBOFAN MOTORUNUN UZUN-KISA SÜRELİ BELLEK YÖNTEMİ YAKLAŞIMI İLE KESTİRİMCİ BAKIMI.
- Wang, T., Yu, J., Siegel, D., and Lee, J. (2008, October). A similarity-based prognostics approach for remaining useful life estimation of engineered systems. In 2008 international conference on prognostics and health management (pp. 1-6). IEEE.
- Wang, W., and Zhang, W. (2005). A model to predict the residual life of aircraft engines based upon oil analysis data. *Naval Research Logistics (NRL)*, 52(3), 276-284.
- WHITE, E. S. W. (1998). System modeling and simulation for predictive maintenance. *Cybernetics and Systems*, 29(5), 481-498.
- Widodo, A., and Yang, B. S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574..
- Wu, H., Huang, A., and Sutherland, J. W. (2020). Avoiding environmental consequences of equipment failure via an LSTM-based model for predictive maintenance. *Procedia Manufacturing*, 43, 666-673.
- Xiong, M., Wang, H., Fu, Q., and Xu, Y. (2021). Digital twin-driven aero-engine intelligent predictive maintenance. *The International Journal of Advanced Manufacturing Technology*, 114(11), 3751-3761.
- Yadav, G., and Paul, K. (2021). Architecture and security of SCADA systems: A review. *International Journal of Critical Infrastructure Protection*, 34, 100433.
- Yağcı, M. Y. (2020). SCADA sistemler için güvenli model oluşturulması (Yüksek lisans tezi). İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı.
- Yaman, G., ve Karadayı, H. M. (2014). Titreşim analizi ile pompalarda arıza tesbiti ve kestirimci bakım için örnek bir çalışma. *Tesisat Mühendisliği*, 140(140), 37-51.
- Yang, B. S., Han, T., and Hwang, W. W. (2005). Fault diagnosis of rotating machinery based on multi-class support vector machines. *Journal of Mechanical Science and Technology*, 19(3), 846-859.

- Ye, Y., Yong, Z., and Han, D. (2020). Research on key technology of industrial artificial intelligence and its application in predictive maintenance. *Acta Automatica Sinica*, 46(10), 2013-2030.
- Yildirim, S., and Rana, Z. A. (2024). Enhancing aircraft safety through advanced engine health monitoring with long short-term memory. *Sensors*, 24(2).
- Yuan, M., Wu, Y., and Lin, L. (2016, October). Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. In *2016 IEEE international conference on aircraft utility systems (AUS)* (pp. 135-140). IEEE.
- Zeigler, B., Muzy, A., and Yilmaz, L. (2012). Artificial intelligence in modeling and simulation. In *Computational Complexity* (pp. 204-227). Springer, New York, NY.
- Zhang, D., Lin, J., Peng, Q., Wang, D., Yang, T., Sorooshian, S., ... and Zhuang, J. (2018). Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm. *Journal of Hydrology*, 565, 720-736.
- Zhao, R., Wang, D., Yan, R., Mao, K., Shen, F., and Wang, J. (2017). Machine health monitoring using local feature-based gated recurrent unit networks. *IEEE Transactions on Industrial Electronics*, 65(2), 1539-1548.
- Zonta, T., Da Costa, C. A., da Rosa Righi, R., de Lima, M. J., Da Trindade, E. S., and Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers and industrial engineering*, 150, 106889

ÖZGEÇMİŞ

ORCID NO: 0009-0001-0359-0697

Ad Soyad : **Ufuk HİMMET**

Yabancı Dil : **İngilizce**

Eğitim ve Mesleki Geçmişi:

- 2024, Elektronik Sistemler Müdürü, ESGAZ, Elektronik Sistemler Müdürlüğü
- 2018, Elektronik Sistemler Şefi, ESGAZ, Elektronik Sistemler Müdürlüğü
- 2017, Elektronik Sistemler, SCADA ve Ölçüm Uzman Mühendisi, ESGAZ, Elektronik Sistemler Müdürlüğü
- 2015, Elektronik Sistemler, SCADA ve Ölçüm Mühendisi, ESGAZ, Elektronik Sistemler Müdürlüğü
- 2014, Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendiliği

Yayınları ve/veya Bilimsel/Sanatsal Faaliyetleri:

- Ufuk HİMMET, U (2020). Tramvay ;Hatlarının Oluşturduğu Kaçak Akımın Doğal Gaz Çelik Hatlarındaki Katodik Korumaya Etkisinin İncelenmesi. Gastechnics , Sayı (104) , 52-55.
- 2019, INGAS 2019- 8.Uluslararası Doğal Gaz Kongre ve Fuarı, Tramvay ;Hatlarının Oluşturduğu Kaçak Akımın Doğal Gaz Çelik Hatlarındaki Katodik Korumaya Etkisinin İncelenmesi Konulu Sunum, Haliç Kongre Merkezi

Ödülleri:

- 2014, Bölüm 2.si, Başarı Belgesi, Ondokuz Mayıs Üniversitesi
- 2014, Onur, Onur Belgesi, Ondokuz Mayıs Üniversitesi

Mesleki Birlik/Dernek/Kuruluş Üyelikleri:

- 2016, Elektrik Mühendisleri Odası, Eskişehir.