

T.C.  
YILDIZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

HAVACILIK ENDÜSTRİSİNDE PROGNOSTİK SAĞLIK  
YÖNETİMİ VE VERİ MADENCİLİĞİ

Meryem ERDOĞAN

YÜKSEK LİSANS TEZİ

Aviyonik Mühendisliği Anabilim Dalı

Aviyonik Mühendisliği Programı

Danışman

Dr.Öğr.Üyesi Muharrem MERCİMEK

Mart, 2024

**T.C.**  
**YILDIZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**HAVACILIK ENDÜSTRİSİNDE PROGNOSTİK SAĞLIK**  
**YÖNETİMİ VE VERİ MADENCİLİĞİ**

Meryem ERDOĞAN tarafından hazırlanan tez çalışması 22.03.2024 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Aviyonik Mühendisliği Anabilim Dalı, Aviyonik Müh. (YL) Programı **YÜKSEK LİSANS** olarak kabul edilmiştir.

Dr.Öğr.Üyesi Muharrem MERCİMEK  
Yıldız Teknik Üniversitesi  
Danışman

**Jüri Üyeleri**

Dr.Öğr.Üyesi Muharrem MERCİMEK, Danışman  
Yıldız Teknik Üniversitesi

Prof. Dr. Özgür Turay KAYMAKÇI, Üye  
Çanakkale Onsekiz Mart Üniversitesi

Dr. Öğr. Üyesi Mümin Tolga EMİRLER, Üye  
Yıldız Teknik Üniversitesi

Danışmanım Dr.Öğr.Üyesi Muharrem MERCİMEK sorumluluğunda tarafımda hazırlanan “Havacılık Endüstrisinde Prognostik Sağlık Yönetimi ve Veri Madenciliği” başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Meryem ERDOĞAN

İmza



*Aileme  
ve  
eşime*

## TEŐEKKÜR

---

Bu yksek lisans tezi boyunca, alıŐmamın baŐından sonuna kadar birok kiŐinin destek ve katkılarıyla bu zorlu yolculuĐu tamamladım. Bu vesileyle, Őkranlarımı sunmak istiyorum. İlk olarak, beni bu tez boyunca ynlendiren ve yneten danıŐmanım Muharrem Mercimek hocama iten teŐekkrlerimi iletiyorum. Tez alıŐmam sırasında benimle fikir alıŐveriŐinde bulunan ve destek olan meslektaŐlarım, arkadaŐlarım ve aileme ayrıca teŐekkr etmek isterim. Sizinle paylaŐtıĐım bu yolculuk, deneyim ve motivasyonumu artırdı. Son olarak, bu sreteki stn fedakarlıĐı ve sabrı iin sevgili eŐim, Osman ErdoĐan'a teŐekkr etmek isterim. Bu alıŐma, sizlerin katkıları ve destekleri olmadan gerekleŐtirilemezdi. Hepinize iten teŐekkr ederim.

Saygılarımla,

Meryem ERDOĐAN

# İÇİNDEKİLER

<b>TEŞEKKÜR</b>	<b>iv</b>
<b>KISALTMA LİSTESİ</b>	<b>vi</b>
<b>ŞEKİL LİSTESİ</b>	<b>vii</b>
<b>TABLO LİSTESİ</b>	<b>ix</b>
<b>ÖZET</b>	<b>x</b>
<b>ABSTRACT</b>	<b>xii</b>
<b>1 GİRİŞ</b>	<b>1</b>
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı .....	4
1.3 Hipotez .....	5
<b>2 HAVACILIK ENDÜSTRİSİNDE PHM KONSEPTİ</b>	<b>6</b>
2.1 Prognostik Yaklaşım .....	13
<b>3 UÇAK SİSTEMLERİNDE PROGNOSTİK YAKLAŞIMLAR VE UYGULAMALARI</b>	<b>17</b>
3.1 Uçak Motor Sistemi .....	17
3.2 Uçak Yapısalları .....	19
3.3 Elektrik Güç Sistemleri .....	20
3.4 Aviyonik Sistemler .....	22
<b>4 CMAPSS UÇAK MOTORU VERİLERİ İÇİN VERİ TABANLI PROGNOSTİK UYGULAMASI</b>	<b>26</b>
4.1 CMAPSS Veri Seti .....	26
4.2 LSTM ve RUL Tahmini.....	35
4.3 Normalizasyon Teknikleri.....	41
4.4 Filtreleme Teknikleri.....	44
<b>5 SONUÇ</b>	<b>52</b>
5.1 Analizler ve Bulgular .....	52
5.2 Bulguların Değerlendirilmesi .....	61
5.3 Tartışma.....	62
5.4 Sonuç.....	67
<b>KAYNAKÇA</b>	<b>69</b>
<b>TEZDEN ÜRETİLMİŞ YAYINLAR</b>	<b>77</b>

## KISALTMA LİSTESİ

---

CAMO	Devamlı Uçuşa Elverişlilik Yönetim Organizasyonu
CBM	Duruma Dayalı Bakım
C-MAPSS	Jet Motoru Simüle Edilmiş Veri Kümesi
CNN	Evrışimli Sinir Ağı
DBN	Derin İnanç Ağı
EHMS	Motor Sağlık Takip Sistemi
EKG	Elektrokardiyogram
EMA	Üstel Hareketli Ortalama
FMEA	Arıza Modu ve Etki Analizi
FNN	İleri Beslemeli Sinir Ağı
GPS	Küresel Konumlama Sistemi
GRU	Kapılı Tekrarlayan Birim
GNN	Grafiksel Sinir Ağı
HMI	İnsan Makina Arayüzü
HPC	Yüksek Basınç Kompresörü
HPT	Yüksek Basınç Türbin
HUMS	Sağlık ve Kullanım Takip Sistemi
IVHM	Entegre Araç Sağlık Yönetimi
LPC	Düşük Basınç Kompresör
LPT	Düşük Basınç Türbin
LSTM	Uzun Kısa Vadeli Bellek
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
MOSFET	Metal Oksit Yarıiletken Alan Etkili Transistor
NASA	Ulusal Havacılık ve Uzay Dairesi
PCC	Pearson Korelasyon Katsayısı
PHM	Prognostik Sağlık Yönetimi
RMSE	Kök Ortalama Kare Hatası
RNN	Tekrarlayan Sinir Ağı
RUL	Kalan Kullanılabilir Ömür
SG	Savitzky-Golay
SHM	Yapısal Sağlık İzleme

## ŞEKİL LİSTESİ

Şekil 2.1 Havacılıkta PHM sistem bileşenlerinin dağılımı .....	8
Şekil 2.2 Havacılıkta PHM sistem bileşenleri detaylı gösterim [48] .....	9
Şekil 2.3 Bakım stratejilerinin gelişimi [55] .....	12
Şekil 2.4 Bir ekipman veya sistemin degradasyonu ve RUL ile ilişkisi [57].....	15
Şekil 2.5 Uçak yer operasyonlarında kullanılan bakım karar destek aktivite örneği [58] .....	16
Şekil 3.1 Turbofan uçak motoru [59].....	17
Şekil 3.2 Uçakların temel yapıları [61].....	19
Şekil 3.3 Boeing 787 elektrik güç üretim ve dağıtım sistemi [64] .....	21
Şekil 3.4 Uçak mimarisine genel bir bakış .....	22
Şekil 3.5 GPS alıcı örneği (The Rockwell Collins GB-GRAM-M) .....	24
Şekil 4.1 a) C-MAPSS yazılımında modellenmiş uçak motoruna ait basitleştirilmiş şema b) bileşenler arasındaki akış modeli (devamı) .....	27
Şekil 4.2 FD001 eğitim veri seti satır ve sütun görüntüsü .....	30
Şekil 4.3 a) Eğitim veri setindeki motor sayısı ve ulaşılabilen maksimum zaman adımı b) test veri setindeki motor sayısı ve çalıştırıldıkları son zaman adımı ilişkisi.....	31
Şekil 4.4 Sensor verileri ve hesaplanan RUL değerleri arasındaki ilişki (devamı).....	34
Şekil 4.5 LSTM hücrenin iç yapısının gösterimi .....	35
Şekil 4.6 Uygulaması yapılan LSTM modeli katmanları.....	39
Şekil 4.7 a) Eğitim veri setinde bulunan sensor_15'e ait orijinal veriler b) normalize edilmiş veriler .....	42
Şekil 4.8 a) Eğitim veri setinde bulunan sensor_15'e ait orijinal veriler b) normalize edilmiş veriler .....	43
Şekil 4.9 sensor_7 için SG filtresi ile gürültü azaltma.....	45
Şekil 4.10 SG filtre uygulaması akış diyagramı .....	46
Şekil 4.11 db4 dalgacık fonksiyonu [72].....	46
Şekil 4.12 Dalgacık dönüşümü ile gürültü azaltma uygulaması.....	47
Şekil 4.13 sensor_7 için dalgacık dönüşümü ile gürültü azaltma.....	49
Şekil 4.14 EMA ile gürültü azaltma uygulaması.....	50
Şekil 4.15 sensor_7 için EMA filtresi ile gürültü azaltma .....	51
Şekil 5.1 comparativeSN_1'de en iyi skora sahip senaryo (SN2) için RUL tahmini.....	54

<b>Şekil 5.2</b> comparativeSN_2'de en iyi skora sahip senaryo (SN8) için RUL tahmini.....	55
<b>Şekil 5.3</b> comparativeSN_3'de en iyi skora sahip senaryo (SN10) için RUL tahmini .....	56
<b>Şekil 5.4</b> comparativeSN_4'de en iyi skora sahip senaryo (SN9) için RUL tahmini.....	57
<b>Şekil 5.5</b> comparativeSN_5'de en iyi skora sahip senaryo (SN10) için RUL tahmini .....	58
<b>Şekil 5.6</b> comparativeSN_6'da en iyi skora sahip senaryo (SN7) için RUL tahmini.....	59
<b>Şekil 5.7</b> comparativeSN_7'da en iyi skora sahip senaryo (SN12) için RUL tahmini .....	60



## TABLO LİSTESİ

---

<b>Tablo 4.1</b> FD001 veri setinde bulunan veriler ve etiketleri .....	28
<b>Tablo 4.2</b> Uygulaması yapılan LSTM modelinin özellikleri .....	37
<b>Tablo 5.1</b> Uygulanan senaryolar ve etiketleri .....	52
<b>Tablo 5.2</b> Kıyaslama senaryoları ve etiketleri.....	53
<b>Tablo 5.3</b> comparativeSN_1 sonuçları.....	55
<b>Tablo 5.4</b> comparativeSN_2 sonuçları.....	56
<b>Tablo 5.5</b> comparativeSN_3 sonuçları.....	57
<b>Tablo 5.6</b> comparativeSN_4 sonuçları.....	58
<b>Tablo 5.7</b> comparativeSN_5 sonuçları.....	59
<b>Tablo 5.8</b> comparativeSN_6 sonuçları.....	60
<b>Tablo 5.9</b> comparativeSN_7 sonuçları.....	61
<b>Tablo 5.10</b> Kıyaslama senaryolarında, comparativeSN_{1-7}, en iyi skora sahip senaryolar.....	62

## **Havacılık Endüstrisinde Prognostik Sağlık Yönetimi ve Veri Madenciliği**

Meryem ERDOĞAN

Aviyonik Mühendisliği Anabilim Dalı

Aviyonik Mühendisliği Programı

Yüksek Lisans Tezi

Danışman: Dr.Öğr.Üyesi Muharrem MERCİMEK

Havacılıkta, Prognostik Sağlık Yönetimi (PHM), uçak bileşenlerinin sağlığını ömürleri boyunca izleyen ve öngörücü bakım imkânı sağlayan karmaşık ve maliyetli bir sistemdir. Dünyada yaygın olarak kullanılsa da Türkiye havacılık endüstrisine veri madenciliğinin entegre edilememesinden dolayı yeterince yaygınlaşamamıştır. Bu çalışmanın amacı, endüstri deneyimleriyle PHM konseptini özetlemek ve veri madenciliğinin yaygınlaşabilmesi için literatürdeki uygulamaları inceleyerek, maliyet etkin ve pratik bir bakış açısıyla endüstri ile literatür arasındaki boşluğu azaltmaktır. Bu çalışmada, PHM'in ana hedefi olan prognostik ve RUL tahmini üzerinde durularak, uçak motorları, aviyonikler, yapısal ve elektrik sistemleri için uygulanan yaklaşımlar incelenmiştir. İncelemelere göre, derin öğrenme modeli ve prognostik yaklaşım seçimi konusunda yönlendirmeler yaygındır; ancak veri ön işleme tekniklerinin ve adımlarının seçimi konusundaki yönlendirmeler sınırlıdır. Bu çalışmada, veri ön işleme adımları ve tekniklerinin kıyaslandığı örnek bir uygulama yapılmış ve gelecek çalışmalar için

daha kapsamlı kıyaslamalar yapılmasının gerekliliği vurgulanmıştır. RUL tahmininde yaygın olarak kullanılan Uzun Kısa Vadeli Bellek (LSTM) modeli seçilmiş ve havacılıkta maliyet etkinliği nedeniyle veri tabanlı prognostik yaklaşıma odaklanılmıştır. Filtreleme adımı için Savitzky-Golay (SG), Üstel Ağırlıklı Ortalama (EMA) ve Dalgacık Dönüşümü, normalizasyon için ise minimum-maksimum ve z-skoru teknikleri seçilmiştir. Uçak motorlarının simülasyon verileri kullanılarak bu tekniklerle farklı veri ön işleme kombinasyonları belirlenmiştir ve LSTM modeli üzerinde uygulanarak, performansına etkisi kök ortalama kare hatası (RMSE) ve Pearson korelasyon kat sayısı (PCC) metrikleri ile incelenmiştir. Bulgulara göre, en yüksek performansın elde edildiği, SG filtreleme ile z-skoru normalizasyonunun birlikte uygulandığı senaryo olmuştur ve RMSE için 13,57 ve PCC için 0,9466 değerleri elde edilmiştir. Ayrıca, normalizasyon teknikleri arasında en iyi performansı z-skoru göstermiş, özellikle EMA ve SG filtreleme ile birlikte uygulandığında daha iyi performans sonuçları elde edilmiştir. Ancak, dalgacık dönüşümü tekniği ile birlikte uygulandığında, minimum-maksimum tekniğinin uygulandığı senaryoya göre model performansının düştüğü gözlemlenmiştir. Farklı tipte veri ön işleme adımlarının birbirlerine olan etkisinin, model performansında farklı sonuçlara neden olabileceği ve bu adımların kombinasyonlarının kıyaslanmasının önemi vurgulanmıştır.

**Anahtar Kelimeler:** Prognostik sağlık yönetimi (PHM), havacılık, veri madenciliği, kalan faydalı ömür (RUL).

## **Data Mining and Prognostic Health Management in the Aviation Industry**

Meryem ERDOĞAN

Department of Avionics Engineering

Master of Science Thesis

Supervisor: Assist. Prof. Dr. Muharrem MERCİMEK

In aviation, Prognostics Health Management (PHM) is a complex and costly system that monitors the health of aircraft components throughout their lifetime and enables predictive maintenance. Although it is widely used in the world, it has not become widespread enough due to the lack of integration of data mining in the Turkish aviation industry. The aim of this study is to summarise the PHM concept with industry experiences and to reduce the gap between the industry and the literature by examining the applications in the literature for the widespread use of data mining from a cost-effective and practical perspective. In this study, the main objective of PHM, prognostics and RUL prediction, is focused and the approaches applied for aircraft engines, avionics, structures and electrical systems are investigated. According to the research, guidance on the selection of deep learning models and prognostic approaches is common, but guidance on the selection of data pre-processing techniques and steps is limited. This study presents a sample

application comparing data pre-processing steps and techniques, and highlights the need for more comprehensive comparisons for future studies. The Long Short-Term Memory (LSTM) model, which is widely used in RUL prediction, is selected and the focus is on a data-driven prognostic approach due to its cost effectiveness in aviation. Savitzky-Golay (SG), Exponential Weighted Average (EMA) and Wavelet Transform are chosen for the filtering step, while minimum-maximum and z-score techniques are chosen for normalization. Using simulation data of aircraft engines, different combinations of data pre-processing with these techniques were identified and applied on the LSTM model and their effect on its performance was analysed by root mean square error (RMSE) and Pearson correlation coefficient (PCC) metrics. According to the findings, the highest performance was obtained in the scenario where SG filtering and z-score normalization were applied together, and values of 13.57 for RMSE and 0.9466 for PCC were obtained. Moreover, z-score showed the best performance among the normalization techniques, especially when applied together with EMA and SG filtering, better performance results were obtained. However, when applied together with the wavelet transform technique, it was observed that the model performance decreased compared to the scenario where the minimum-maximum technique was applied. It is emphasised that the effect of different types of data pre-processing steps on each other may lead to different results in model performance and the importance of comparing the combinations of these steps is emphasised.

**Keywords:** Prognostic health management (PHM), aviation, data mining, remaining useful life (RUL)

## 1.1 Literatür Özeti

Havacılık endüstrisi, gün geçtikçe karmaşıklaşan uçak sistemleri, artan operasyonel talepler, artan maliyetler ve sürekli değişen koşullarla karşı karşıyadır. Bu dinamik ortamda, uçakların bakım ve onarım süreçlerinin optimize edilmesi, operasyonel maliyetlerin düşürülmesi ve uçuş güvenliğinin artırılması kritik öneme sahiptir. Prognostik Sağlık Yönetimi (PHM), bu noktada önemli bir rol oynamaktadır. PHM, ilk olarak 1992 yılında Ulusal Havacılık ve Uzay Dairesi (NASA) tarafından veri toplama, teşhis, tahmin, arızaları azaltma ve uzay araçlarının operasyonel kararlarını ve operasyon sonrası bakım faaliyetlerini destekleme amaçlı bir teknoloji olarak tanıtılmıştır [1].

PHM, uzay araçları, uçaklar ve benzeri kompleks sistemlerin tüm yaşam döngüsü boyunca karşılaşılabileceği zorluklara karşı kapsamlı bir koruma sağlayan bir sistemdir. Bu sistem, gelişmiş sensör teknolojileri kullanarak, bu sistemleri gerçek zamanlı olarak izler, verileri toplar, yönetir, aktarır, arızaları teşhis eder, arıza olasılığını tahmin eder, öngörücü bakım planlaması yapar ve otomatik lojistik destek işlevlerini entegre bir şekilde yönetir. Günümüzde, PHM sistemi, tüm modern ticari uçaklarda kullanılmaktadır. Örneğin, Boeing uçakları [2], Lockheed Martin'in F-35 savaş uçağı [3] ve Airbus uçakları [4] gibi modern ticari ve askeri uçaklar, PHM sistemleri ile donatılmıştır. Bunun yanı sıra, insansız hava araçları [5] ve helikopterler arasında Sikorsky'nin S-92 modeli [6] de bu teknolojiden faydalanmaktadır. Boeing tarafından 2007 yılında üretilen ve günümüzde geliştirmeler ve iyileştirmelerle üretime devam edilen Boeing 787 Dreamliner yolcu uçağı, veri tabanlı prognostik yaklaşımların kullanımına dair önemli bir örnektir. Boeing, bu uçakta sistem sağlığının sürekli olarak izlenmesine yönelik bir PHM sistemi geliştirmiştir. Uçuş sırasında elde edilen veriler uçak yerde olduğunda transfer edilerek, yer operasyonlarında detaylı analizlere olanak sağlamaktadır. Sivil havacılıkta PHM kavramı aynı zamanda Entegre Araç Sağlığı Yönetimi (IVHM) olarak da adlandırılmaktadır. Bu entegre sistem, uçağın tüm sistemlerinin sağlık durumunu izlemek ve yönetmek amacıyla geliştirilmiştir [7]. Boeing'in PHM

sistemi sayesinde, uçak sistemlerinin bakım ve onarım zamanları optimize edilmiş, bu da uçak bakım maliyetlerinin %30'a kadar düşmesine ve uçakların operasyonel kullanılabilirliğinin artmasına önemli seviyede katkı sağlamıştır [2].

PHM sisteminin temelde amacı, ekipman veya sistem bakımını optimize etmek için prognostik yaklaşımların uygulanmasıdır. Literatürde, bir ekipman veya sistemin kalan kullanılabilir ömür (RUL) tahmini, ekipmanın arızalanmadan önce çalışabilir durumda kalabileceği tahmini bir zaman aralığı, için çeşitli prognostik yaklaşımlar mevcuttur. Bu yaklaşımlar genellikle veri odaklı, fizik tabanlı ve hibrit tabanlı olarak sınıflandırılır. Fizik tabanlı ve hibrit tabanlı yaklaşımlar [8, 9] yaygın olarak kullanılmaktadır, ancak karmaşıklıkları ve uçak sistemleri hakkında derinlemesine bilgi gerektirmeleri nedeniyle havayolu şirketleri ve uçak üreticileri tarafından daha az tercih edilir. Havacılık endüstrisinde, özellikle havayolu şirketleri ve uçak imalat şirketleri arasında, maliyet etkin yöntemlere yönelik açık bir eğilim vardır. Özellikle, veri odaklı prognostik yaklaşımların fizik tabanlı veya hibrit tabanlı alternatiflere tercih edilmesi söz konusudur [7, 10].

Veri tabanlı prognostik yaklaşımlar incelendiğinde, RUL tahmini için kullanılan yaygın derin öğrenme teknikleri mevcuttur. Bunlardan, Uzun Kısa Vadeli Bellek (LSTM), Evrişimli Sinir Ağı (CNN), İleri Beslemeli Sinir Ağı (FNN), Derin İnanç Ağı (DBN) ve Grafıksel Sinir Ağı (GNN) gibi çeşitli veri odaklı derin öğrenme modelleri, RUL tahmininde etkili olduğunu kanıtlamıştır [11, 12, 13, 14, 15, 16, 17, 18, 19]. Model performansını iyileştirmek için çeşitli varyantlar da geliştirilmiştir. Örneğin LSTM için BiLSTM, GRU, Peephole LSTM ve Vanilla LSTM gibi modeller bulunmaktadır [20]. RUL tahmininde ayrıca CNN-LSTM gibi birleşik modeller (ensemble) de kullanılmaktadır; bu modeller, farklı derin öğrenme mimarilerinin avantajlarını kullanarak ve birbirlerine entegre edilerek daha güvenilir tahmin sonuçları elde etmeyi hedeflemektedir [9, 20]. 2023 yılında gerçekleştirilen son derece kapsamlı bir araştırma [21], RUL tahmini için kullanılan modelleri detaylı bir şekilde incelemiş ve bu modellerin avantajları ile dezavantajlarını ortaya koymuştur. Elde edilen bulgular, havacılık endüstrisi için en uygun modelin seçilmesi konusunda değerli bir rehberlik sunabilir. Bu çalışma, ABD ordusu mühendislik araştırma ve geliştirme merkezi (ERDC) tarafından desteklenmiştir.

Veri tabanlı prognostik yöntemler incelendiğinde, derin öğrenme modelleri üzerinde kapsamlı araştırmalar yapılmıştır. Bu araştırmalar genellikle derin öğrenme modelleri arasındaki üstünlükleri belirlemeye odaklanmıştır. Örneğin, bir çalışmada [22], C-MAPSS motor verileri kullanılarak, RUL tahmini için 10 farklı makine öğrenimi modeli kullanılmış ve bu modeller birbirleriyle karşılaştırılmıştır.

Pratik ve maliyet etkin bir yaklaşım geliştirebilmek için veri ön işleme tekniklerinin kapsamlı bir şekilde karşılaştırılması önemlidir. Yabancı literatürde, veri ön işleme tekniklerinin kombinasyonlarının model performansına etkisini inceleyen ve kıyaslayan sınırlı sayıda çalışmanın olduğu gözlenmektedir. Sadece normalizasyon tekniklerini karşılaştıran [23, 24] veya sadece filtreleme tekniklerini karşılaştıran [25, 26] çalışmalar bulunmaktadır. Örneğin bir çalışmada 38 farklı veri seti kullanılarak 10 farklı normalizasyon tekniği için kıyaslama yapılmıştır. Normalizasyon tekniklerinin kendi içlerinde kıyaslanması gerektiğini ve literatürde onlarca normalizasyon tekniği bulunduğundan bahsedilmiştir [23]. Farklı türde veri ön işleme adımlarının birlikte veya tek başına nasıl uygulandığını karşılaştıran bir çalışma eksikliği bulunmaktadır. Havacılıkta, her bir sistem için ayrı veri tabanlı prognostik modelinin maliyet etkin ve uygulanabilir olmaması göz önüne alındığında, benzer verilere sahip uçak sistemleri veya ekipmanlar için belirlenmiş uygun veri ön işleme adımları ve derin öğrenme modelini içeren ortak bir standardın gerekliliği ortaya çıkmaktadır.

Literatürde yaygın olarak kullanılan teknikler ve adımlar, veri ön işleme adımlarının birlikte kullanıldığı durumu kıyaslamak için başlangıç noktası oluşturabilir. Özellikle, ölçülen sensör verisinin yapısını geliştirmek ve gereksiz gürültüyü minimize etmek amacıyla normalizasyon ve filtreleme yöntemleri yoğun bir şekilde kullanılmaktadır. Bu yöntemlerden biri olan Savitzky-Golay (SG) filtreleme tekniği, zaman serisi verilerinde gürültüyü azaltmak için çeşitli alanlarda yaygın bir uygulama bulmuştur [27, 28, 29]. Zaman serisi verilerinde gürültüyü azaltmak için diğer etkili bir teknik de sensör verileri veya elektrokardiyogram (EKG) sinyalleri gibi zaman serisi verilerinde kullanılan dalgacık dönüşüm ile gürültü azaltma yöntemidir [30, 31, 32, 33]. Son olarak, üstel hareketli ortalama (EMA) tekniği de zaman serisi veriler için kullanılan bir filtreleme yöntemidir. Bu teknik, verideki ani dalgalanmalarını azaltarak daha düzgün bir eğri elde etmeyi amaçlar. Özellikle gürültülü sensör verilerinde ani dalgalanmaların neden olduğu

istenmeyen etkileri azaltmak için etkili bir filtreleme yöntemidir [34]. EMA filtreleme tekniđi, RUL tahmin alıřmalarında kullanılan eđitim ve test veri setlerinde bařarıyla uygulanmıřtır [35, 36, 37, 38].

Normalizasyon, sensör verileri farklı birimlerde veya ölçeklerde olduđunda kullanılır. RUL tahmini için kullanılan sensör ölçüm verileri genellikle farklı birimlere veya ölçeklere sahiptir. Örneđin, bir sensör sıcaklık deđerlerini temsil edebilirken bařka bir sensör titreřim deđerlerini temsil edebilir. Bu farklı ölçekler, derin öğrenme modelinin desenleri ve iliřkileri dođru bir řekilde öğrenmesini zorlařtırabilir. Normalizasyon, veriyi belirli bir aralıđa veya standart bir dađılıma dönüřtürerek ölçek farklarını ortadan kaldırır ve modellerin daha tutarlı ve karřılařtırılabilir sonuçlar üretmesini sađlar [39]. Genel olarak, minimum-maksimum [40, 11, 41] ve z-skoru normalizasyonu [42, 43], RUL tahmini için yaygın olarak kullanılan normalizasyon teknikleridir.

## 1.2 Tezin Amacı

Bu tezin ve gerekleřtirilen alıřmaların amacı sırasıyla ařađıda belirtilmiřtir;

- Havacılık sektöründeki PHM kavramını sektör deneyimi ile açıklamak ve temel uçak sistemleri için yapılan alıřmalardaki prognostik yaklařımları genel bir çerçevede tanıtmak,
- Öngörücü bakımın havacılık endüstrisindeki rolünü, uçakların operasyonel kullanılabilirliđi, güvenilirliđi, filo yönetimi, bakım maliyetleri ve süresi açısından önemini vurgulamak,
- Veri madenciliđi alanındaki geliřmeleri havacılık endüstrisi ile daha uyumlu hale getirerek, iki alan arasındaki bilgi ve uygulama bořluđunu azaltmak.
- Veri madenciliđi kapsamında özellikle farklı veri ön iřleme adımları için kombinasyonlar halinde kapsamlı kıyaslama yapılmasının gerekliliđini yapılan uygulamalarda elde edilen bulgular ile vurgulamak.

### 1.3 Hipotez

Aşağıda belirtilen hipotezler, çalışmanın temel varsayımlarını açıklamakta olup, araştırma sürecinde incelenmiş ve çalışmanın sonuçlarına dayanarak çıkarımlar yapılmıştır.

**Hipotez 1**, veri tabanlı prognostik yaklaşımların, havacılık endüstrisindeki RUL tahmini için maliyet etkin bir çözüm sunacağı beklentisine dayanmaktadır. Fizik veya hibrit tabanlı prognostik yaklaşımlarına kıyasla daha düşük maliyetli ve daha hızlı çözümler sunma potansiyeline odaklanmaktadır.

**Hipotez 2**, derin öğrenme modelleri üzerinde en iyi performans gösterebilecek veri ön işleme adımlarının, yüksek doğrulukla RUL tahminleri elde etmeye olanak tanıyacağı beklentisine dayanmaktadır. Farklı normalizasyon teknikleri ve filtreleme yöntemlerinin farklı kombinasyonlarda uygulandığında derin öğrenme model performansını etkileyebileceği üzerinde durmaktadır.

**Hipotez 3**, prognostik yaklaşımları incelediğimizde, elektrik, elektronik, mekanik ve elektromekanik bileşenlere sahip temel uçak sistemlerine odaklanarak, genel bir veri madenciliği yaklaşımının belirlenebileceği ve uçaktaki diğer tüm sistemlerin de benzer şekilde ele alınabileceği varsayımını içermektedir. Bu gruplandırma ile maliyet etkin prognostik yaklaşımların tüm uçak alt sistemlerinde uygulanabilirliğini desteklemesi yönünde bir adım niteliği taşıması beklenmektedir.

## HAVACILIK ENDÜSTRİSİNDE PHM KONSEPTİ

---

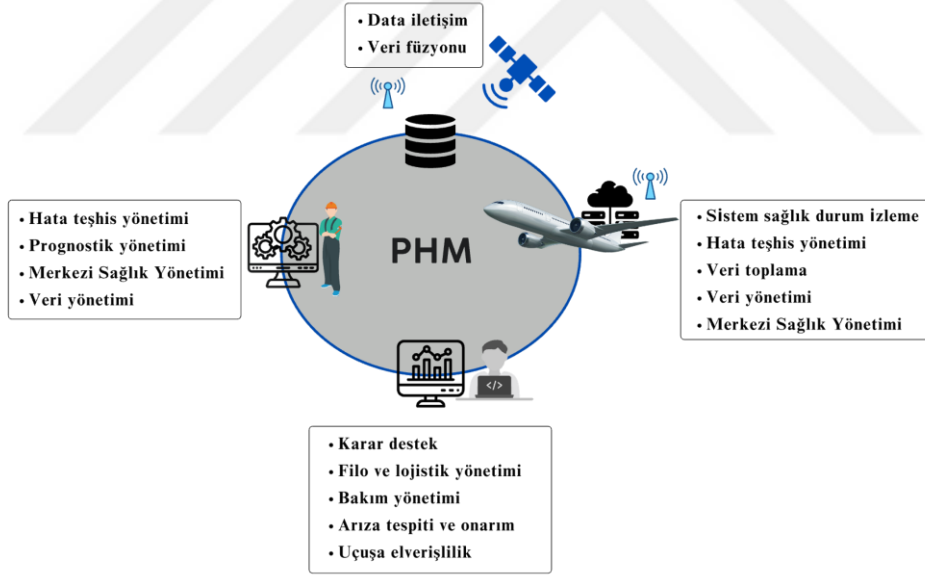
PHM, havacılık sektöründe uzun yıllardan beri farklı isimlendirmeler ve konseptler altında, sağlık takip ve öngörücü bakım fonksiyonu olarak varlığını sürdürmüştür. Örneğin, helikopterlerde Sağlık ve Kullanım Takip Sistemi (HUMS) olarak adlandırılan bu sistemde, mekanik parçaların sürekli izlenmesi ve öngörücü bakımın yapılması sağlanmıştır [44]. Sivil havacılıkta ise, uçaktaki belirli sistemlere odaklanan çeşitli konseptler mevcuttur. Örneğin, motor sağlığı için Motor Sağlık Takip Sistemi (EHMS) gibi özelleşmiş terminolojiler, belirli uçak sistemlerinin izlenmesi ve bakımının planlanması için kullanılmaktadır. Ancak, bu uçak ihtiyaçları veya sistemlere göre özelleşmiş uygulamaların yanı sıra, kapsamlı bir PHM konsepti ve uygulaması ihtiyacı özellikle 5. nesil savaş uçakları gibi ileri teknolojiye sahip hava araçlarında önem kazanmaktadır. Örneğin, F-35 gibi 5. nesil savaş jetleri [3], PHM konseptini bir bütün olarak benimseyerek, hava aracının tüm sistemlerini kapsayan bir sağlık yönetimi yaklaşımını hayata geçirmiştir. PHM konseptinin bütünsel bir şekilde anlaşılması ve ele alınması, 5. nesil savaş jeti üreticisi olan bir ülke olarak Türkiye için de hayati öneme sahiptir. PHM sistem konsepti uçaktan uçağa farklılık gösterebileceğinden, uçak tasarım süreçlerinin erken aşamalarından itibaren bir bütün olarak kurgulanması ve uçak alt sistemlerinin tamamı için ortak yaklaşımların belirlenerek sistem tasarımlarının yapılması gerekmektedir. Adeta bir bütünü oluşturabilecek alt parçalar, bu bütüne hizmet edecek şekilde uyum içerisinde tasarlanmalıdır. Bu, her bir alt sistemde kullanılacak yaklaşımların birbirleriyle entegre bir şekilde çalışabilmesi ve genel uçak performansını artırabilmesi için hayati öneme sahiptir. Aynı zamanda, bu erken bütünleşik yaklaşım, maliyet etkin çözümlerin geliştirilmesine, bakım stratejilerinin optimize edilmesine ve uçakların ömrü boyunca daha etkin bir şekilde yönetilmesine olanak tanıyabilir. Bu nedenle, PHM sistemi, uçak tasarım süreçlerinin temel bir unsuru olarak ele alınmalı ve bütüncül bir perspektifle değerlendirilmelidir.

PHM, havacılık sektöründe hem hava yollarına hem de uçak üreticilerine önemli katkılarda bulunmaktadır. Sistem, erken arıza tespiti, artırılmış uçak güvenliği, uçakların yerde bekleme sürelerinin azaltılması, bakım planlamasının optimize edilmesi, maliyet tasarrufu gibi birçok avantaj sunmaktadır. PHM, uçak sistemlerinde potansiyel arızaların erken tespitini sağlayarak uçuş sırasında meydana gelebilecek arızaların ve plansız bakımın riskini azaltmaktadır. Bu, bakım ekiplerine sorunlara öngörücü bir şekilde müdahale etme imkânı tanımaktadır. PHM, kritik sistemleri sürekli olarak izleyerek uçak güvenliğini artırmaktadır. Sistem, potansiyel güvenlik sorunlarını belirleyebilir, böylece zamanında müdahale ve önleyici tedbirlerle yolcuların ve uçuş ekibinin güvenliğini sağlar. Uçakların yerde bekleme sürelerinin azaltılması noktasında PHM, erken tespit ve öngörücü bakım sağlayarak uçakların işlem dışı kalma süresini en aza indirir. Bu, operasyonel kullanılabilirliği artırır ve özellikle ticari havayolu şirketleri için hayati önem taşır. Örneğin, Airbus'ın A320 uçaklarında öngörücü bakımın uygulanması ile uçakların operasyonel kullanılabilirliği 0,73 ten 0,96 ya artmıştır [45]. Bir diğer örnek ise, AH-64 helikopterlerinde operasyonel kullanılabilirliğin artması ile yani, toplam uçuş zamanında 2,43 oranında artış sağlamıştır [46]. Bakım planlamasının optimize edilmesi adına PHM, uçak bileşenlerinin sağlık durumu hakkında veri odaklı bilgiler sunar. Bu da bakım programlarını optimize etmeye yardımcı olur, parçaların gerçek kullanım ve duruma dayalı olarak hizmet verilmesini sağlar. Maliyet tasarrufu perspektifinden PHM, öngörücü bakım ve optimize edilmiş planlama ile maliyet tasarrufu sağlar. Havayolları daha verimli bir şekilde çalışabilir hem doğrudan bakım maliyetlerini hem de uçuş gecikmeleri ve iptalleri ile ilgili dolaylı maliyetleri en aza indirebilirler. Örneğin, Airbus'ın A320 uçaklarında öngörücü bakım uygulanması ile %80 bakım maliyetleri düşmüştür [45]. Geliştirilmiş güvenilirlik ve performans açısından PHM, arızaları önceden tespit ederek uçakların genel güvenilirliğini artırır. Bu durum, daha güvenilir bir filo ve artan zamanında performans demektir. Uzaktan izleme ve teşhis yetenekleri sayesinde PHM, bakım ekiplerine sorunları uzaktan izleme ve teşhis etme imkânı sunar, bu da kapsamlı yerinde incelemelerin gerekli olmadığı durumları azaltır. Örneğin, H53 helikopterlerinde yerde bakım için harcanan zaman azalmıştır [47]. Geliştirilmiş filo yönetimi bakımından PHM, birden fazla uçağı olan havayolları için merkezi filo yönetimini kolaylaştırır. Operatörler, filonun sağlığını ve performansını izleyebilir, kaynakları optimize etmek ve filonun genel sağlığını

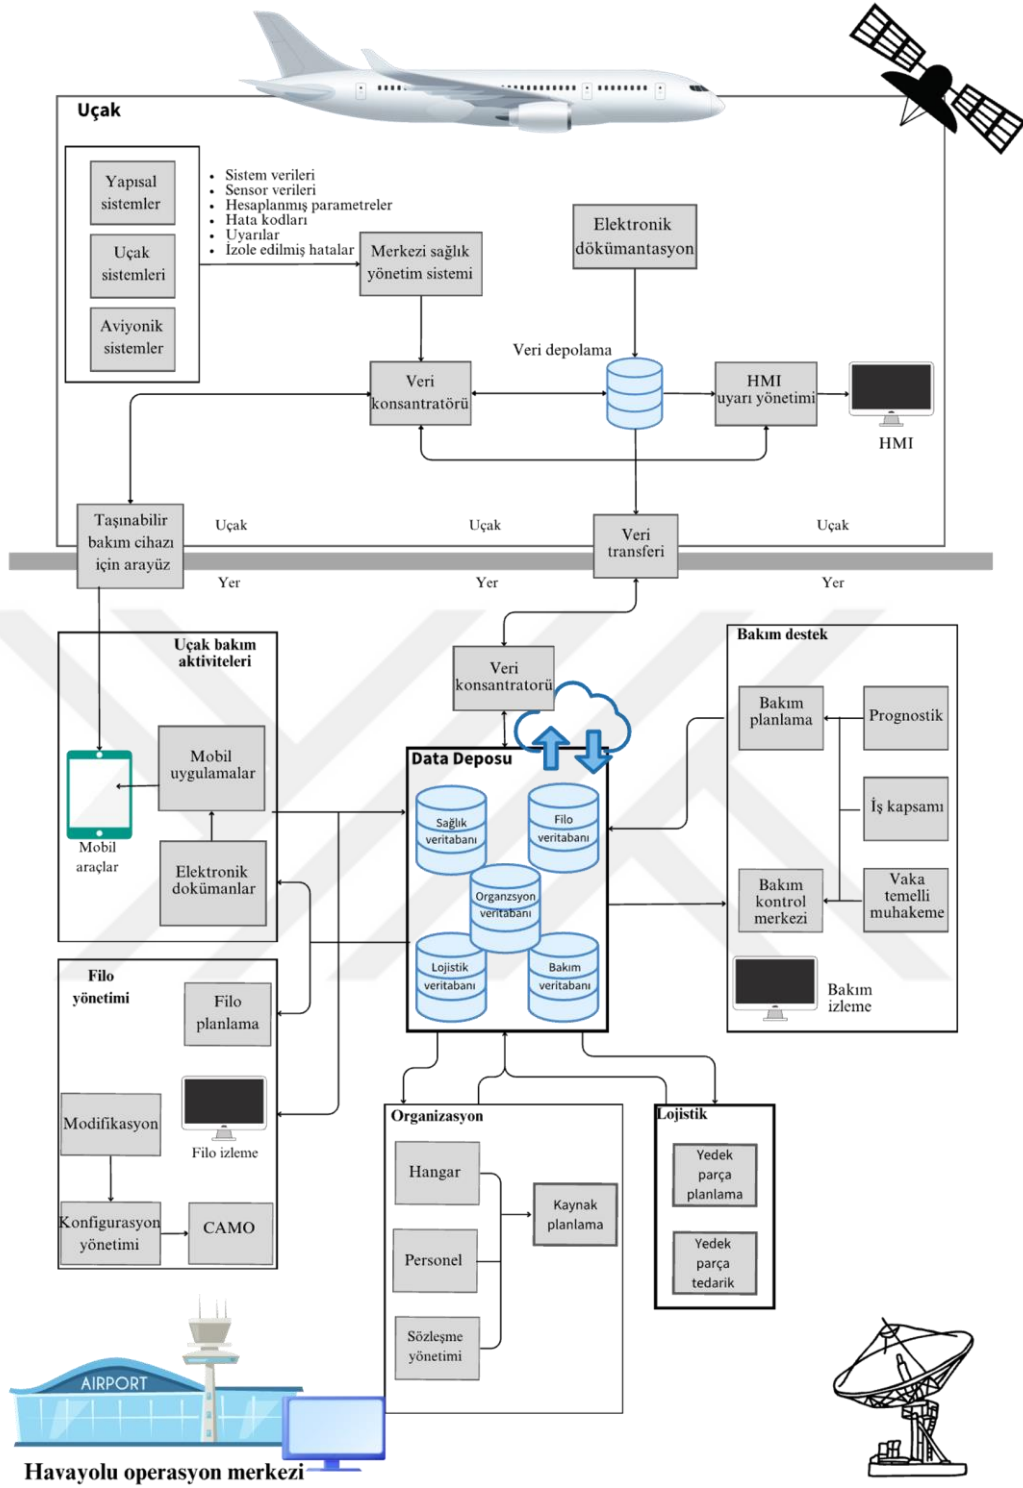
sağlamak için stratejik kararlar alabilirler. Son olarak, gelişmiş uçuş veri analizi PHM'in sağladığı bir avantajdır. Zengin veri kaynağı ile uçak performansı derinlemesine analiz edilebilir, bu da havayollarının operasyonel verimliliği artırmalarına ve sürekli iyileştirmelere olanak tanır.

Özetle, PHM, kompleks sistemlerin ömürleri süresince önemli avantajlar sağlayan bir teknolojidir. Erken arıza tespiti, artırılmış güvenlik, uçakların yerde bekleme sürelerinin azaltılması, bakım planlamasının optimize edilmesi, maliyet tasarrufu, geliştirilmiş güvenilirlik ve performans, uzaktan izleme ve teşhis, geliştirilmiş filo yönetimi ve gelişmiş uçuş veri analizi gibi önemli avantajlar sunmaktadır.

PHM sisteminin temel bileşenlerinin genel dağılımı **Şekil 2.1**'de ve detaylı gösterimi **Şekil 2.2**'de verilmiştir. **Şekil 2.1**'de [48]'da verilen genel IVHM konsepti ve havacılık sektöründe elde edilen deneyimlerden yararlanılarak kurgulanmıştır.



**Şekil 2.1** Havacılıkta PHM sistem bileşenlerinin dağılımı



Şekil 2.2 Havacılıkta PHM sistem bileşenleri detaylı gösterim [48]

PHM sisteminin temel bileşenleri, uçak içi ve yer sistemleri olmak üzere iki ana başlıkta toplanabilir. Uçak içi bileşenler, uçak sistemlerinin ve ekipmanlarının sağlık durumunun izlenmesi ve takibi, hata teşhis yönetimi, verilerin toplanması ve

yönetimini içerir. Yer sistemleri bileşenleri ise, tüm uçaklardan gelen verilerin büyük veri depolama sistemlerinde kayıt edilmesi, bu verilerle kapsamlı hata teşhis ve prognostik aktivitelerinin yapılması, entegre olarak uçakların veya sistemlerin mevcut sağlık durum değerlendirmesi ve gelecekteki sağlık durumlarının tespiti ve yönetimini içerir. Bu bileşenlerin çıktıları, karar destek, filo ve lojistik yönetimi, bakım yönetimi, arıza tespiti ve onarımı gibi uçak yer operasyonları tarafından kullanılır [49, 50, 51, 52].

Uçuş sırasında verilerin toplanması, uygun formata getirilerek kayıt edilmesi ve bu verilerin uçaktan yer veri depolama sistemlerine transfer edilmesi, PHM' in temel fonksiyonlarından. Uçaktaki sistemlere ait sensörler, çeşitli parametreleri sürekli veya belirli aralıklarla uçuş veya operasyon sırasında ölçer. Sıcaklık, basınç, titreşim, hız, akım, voltaj gibi çeşitli fiziksel ölçümler arasında bulunan parametreler, emniyet kritik durumları tespit etmek ve pilota gerekli uyarıları iletmek için kullanılır. PHM yaklaşımında ise bu amaca ek olarak, sistem veya ekipmanın sağlığı ile ilişkili tüm sensor verileri veya hesaplanmış parametreler uçakta kayıt edilir ve uçak yere indiğinde, bu veriler yer veri depolama sistemlerine transfer edilir. PHM, çeşitli veri iletişim teknolojilerini kullanarak veri transferini gerçekleştirir. Uçakta, sensörlerden toplanan veriler genellikle dijital formatta merkezi sağlık yönetim sistemine iletilir. Eğer analog sensörler kullanılıyorsa, bu veriler dijitalle çevrilerek iletilir [53]. Uçakta bulunan merkezi sağlık yönetimi ve bilgi sistemi aracılığıyla verilere gerekli kriptolama, sıkıştırma, filtreleme gibi çeşitli veri yönetimi fonksiyonları uygulanarak, uçak yere indiğinde bu veriler wifi, kablolu bağlantı veya hücreli ağ bağlantısı üzerinden yer depolama sistemlerine dosyalar halinde transfer edilir.

Yer veri depolama sistemlerinde toplanan büyük veriler, uçak yer operasyonlarının bir parçası olan prognostik yönetimi için önemli bir kaynaktır. Prognostik yaklaşım, sensör teknolojilerindeki gelişmeler, makine öğrenimi alanındaki ilerlemeler, büyük verinin giderek artması ve veri analizinde yeni yaklaşımların gelişmesi ile havacılıkta önemli bir yer edinmiştir. Bu yöntem, bir sistemin veya ekipmanın gelecekteki performansını tahmin etmek için kullanılır. Sensör verileri, makine öğrenimi modelleri, bakım geçmişi, çevresel koşullar ve teknik şartname bilgileri kullanılarak, sistemin veya ekipmanın mevcut durumu değerlendirilir ve bu bilgiler temelinde gelecekteki performansına dair öngörülerde bulunulur. Prognostik

yaklaşımın çıktıkları, işletmeciler ve operatörler için önemli faydalar sağlar. Bakım tahminleri, daha etkili bir bakım stratejisi oluşturmak isteyen işletmecilere yardımcı olur. Hata ve arıza uyarıları, operatörlere potansiyel sorunları önceden belirleme konusunda bilgi sağlar. RUL tahminleri ise bakım zamanlamasını optimize etme ve kaynakları daha verimli kullanma konusunda girdi sağlar. Özetle, uçaklar için yer operasyonlarında prognostik yönetim genellikle uçak filosunun sağlık verilerini kullanarak analiz etmeyi, bakım ihtiyaçlarını tahmin etmeyi ve operasyonel verimliliği artırmayı içerir. Bu süreç, büyük veri analitiği, makine öğrenimi ve derin öğrenme teknolojilerini içerir.

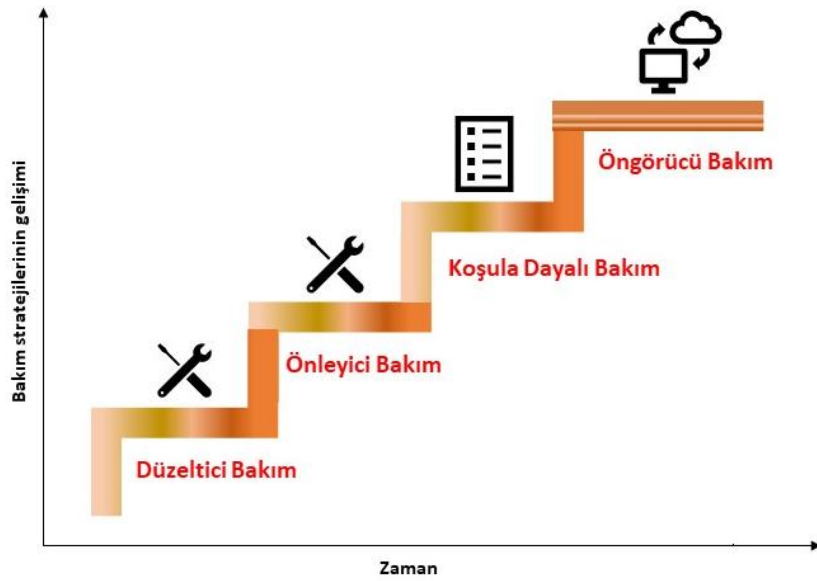
Yer operasyonlarında işlenen sağlık verilerinden elde edilen analiz sonuçları, bakım operasyonları için öneri formları oluşturur. Bu öneri formları, bakım ekiplerinin uçakların güvenli ve verimli çalışmasını sağlamak için ihtiyaç duydukları bilgileri sağlar. Uçak bakımı, uçakların güvenli ve verimli işleyişini sağlamak, düzenleyici standartlara uygunluğu sürdürmek, aşınma ve yıpranmayı kontrol etmek, öngörülebilir performans elde etmek ve potansiyel arızaları önceden önlemek amacıyla gerçekleştirilen bir dizi işlemdir. Uçak bakımının temel hedefleri arasında uçuş güvenliğini sağlamak, sistemlerin havacılık standartlarına uygunluğunu sürdürmek ve uçak ömrünü uzatmak bulunur. Uçak bakımı, teknik ekipmanın durumunu izlemeyi, gerektiğinde onarımları veya değişiklikleri içerir ve genel olarak uçağın güvenliği ve verimliliğini korumak için kapsamlı bir stratejiyi içerir.

Havacılıkta bakım stratejileri, uçakların güvenli ve etkin bir şekilde uçabilmesi için tasarlanmış yaklaşımları içerir. Havacılık bakım stratejilerinde tarihsel bir perspektifle değerlendirildiğinde, geleneksel yöntemler arasında önleyici bakımın öne çıktığını görüyoruz. Bu metot, belirli aralıklarla planlanan rutin müdahaleleri içeriyordu ve bileşenleri gerçek durumlarına bakılmaksızın değiştirmeyi amaçlıyordu. Ancak, aşınma ve yıpranmayı ele almadaki etkinliğine rağmen, sıklıkla gereksiz parça değişimlerine neden olmasıyla bakım maliyetlerini ciddi bir şekilde artırıyor ve uçakların hizmet dışı kalma sürelerini uzatıyordu [54].

Önleyici bakımın yanı sıra, yaygın olarak uygulanan diğer bir strateji de düzeltici bakımdı. Bu yaklaşım, sorunların ancak meydana geldikten sonra müdahale edilmesini içeriyordu, yani temelde bir arıza oluşmasını beklemeyi gerektiriyordu. Bu durum, planlanmamış arızalara, yüksek onarım maliyetlerine ve geciken uçuşlara neden olarak yolcu memnuniyetsizliğiyle sonuçlanabiliyordu [54].

Duruma dayalı bakım (CBM), sensörler aracılığıyla gerçek zamanlı izleme sağlayarak önemli bir ilerleme olarak ortaya çıktı. Ancak CBM, genellikle durumları izlenen parçaların anlık durumuna odaklandığı için gelecekteki sorunları etkili bir şekilde tahmin etmekte sınırlıydı.

Öngörücü bakımın devreye girmesiyle havacılık bakımında önemli bir değişim yaşandı. Gelişmiş analitik, makine öğrenimi ve veri odaklı algoritmalarla desteklenen bu strateji, geçmiş verileri analiz ederek ve kalıpları belirleyerek potansiyel arızaları öngörmeyi amaçladı. Bu yaklaşım, arıza sürelerini azaltmaya, bakım maliyetlerini düşürmeye ve genel operasyonel verimliliği artırmaya önemli ölçüde katkıda bulundu. Öngörücü bakım, havacılık endüstrisinde reaktif ve programlı yaklaşımlardan öngörücü bir modele geçişi simgeliyor. Bu geçiş, sadece uçak bakımında devrim yaratmakla kalmadı, aynı zamanda sektörün emniyet, güvenilirlik ve maliyet etkinliğini artırma konusundaki kararlılığının da vurgusunu oluşturdu [54]. Bakım stratejilerinin tarihsel gelişimi **Şekil 2.3**'de verilmiştir.



**Şekil 2.3** Bakım stratejilerinin gelişimi [55]

## 2.1 Prognostik Yaklaşım

Havacılık sektöründe, prognostik yaklaşım, yer operasyonlarında karar alma süreçlerini optimize etmek için kritik bir rol oynamaktadır. Prognostik yaklaşımın başarıyla uygulanabilmesi için, uçak sistemlerinin bu perspektifle tasarlanması ve alt sistem tasarımlarının da tedarikçi ve alt yüklenici firmalar tarafından benimsenmesi gerekmektedir. Her sistemde farklı tasarımlar ve davranışlar bulunsa da prognostik yaklaşımla entegre bir şekilde çalışabilen ortak bir yöntem geliştirilmelidir. Uçaklarda bulunan merkezi sağlık yönetim sistemi, merkezi bir kural koyucu olarak işlev görerek, her sistemin kapsamlı veri iletimi, kaydı ve transferi için belirlenmiş formatlarda çalışır. Aviyonik sistemler, motor sistemleri, yakıt sistemleri, yapısal sistemler, elektrik ve aydınlatma sistemleri gibi farklı sistemler, sağlık parametrelerini ekipman seviyesinde ve sistem seviyesinde tasarlayarak, bu parametrelerin ölçümü için gerekli sensörleri uçağa entegre ederler. Bu sağlık parametrelerinin uçuş sırasında yapılan ölçümleri, yer sağlık merkezi operasyonlarında prognostik yaklaşımın etkili bir şekilde uygulanabilmesi için önemli bir kaynaktır. Büyük verinin elde edilme aşaması, prognostik yaklaşımın yönetiminde kritik bir rol oynamaktadır. Büyük veri oluştuktan sonra, yer operasyonlarında veri işleme merkezlerinde prognostik yaklaşım uygulanır. Bu aşamada, uygulama yöntemleri genellikle fizik tabanlı, veri tabanlı ve hibrit tabanlı yaklaşımlar olarak sınıflandırılmaktadır [44].

Fizik tabanlı prognostik yöntemler, sistemlerin fiziksel davranışlarına odaklanarak tahminlerde bulunur. Bu yöntem, sistemin fiziksel veya matematiksel modelinin geliştirilmesi, modelin kalibre edilmesi, modelin simülasyonu ve simülasyon verileri kullanılarak tahmin yapılması aşamalarını içerir. Sistem modelinin geliştirilmesi aşamasında, matematiksel modeller kullanılarak sistemin yapısı ve çalışma prensiplerini tanımlayan modeller oluşturulur. Modelin kalibre edilmesi aşamasında, modelin gerçek sistemle uyumlu olması için ölçüm verileri kullanılarak parametreler ayarlanır. Modelin simülasyonu aşamasında, belirlenen koşullarda model çalıştırılır ve elde edilen veriler kayıt altına alınır. Tahminlerin yapılması aşamasında, kalibre edilmiş model ve simülasyon verileri kullanılarak sistemin gelecekteki sağlık durumu makine öğrenimi veya derin öğrenme algoritmaları kullanılarak sisteme ait sağlık parametreleri tahmin edilir. Fizik tabanlı yöntemler, genellikle yüksek doğruluk ve güvenilirlik sağlar. Ancak, uçak

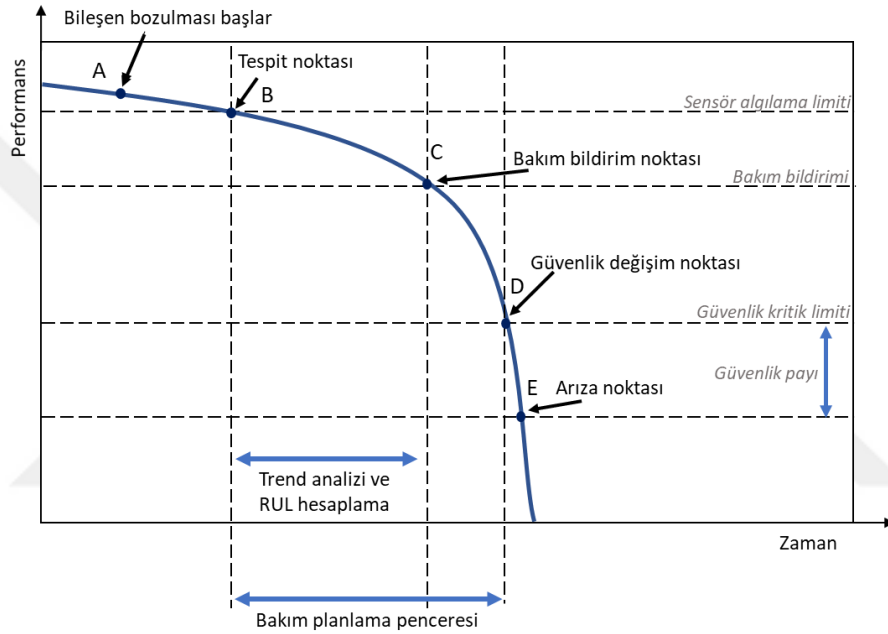
sistemlerinin karmaşıklığına bağlı olarak model geliştirme ve kalibrasyon süreçleri zaman alıcı ve maliyetlidir.

Veri tabanlı prognostik yöntemler ise geçmiş verilerden yararlanarak tahminler yapar. Bu yöntem, verilerin toplanması, veri ön işleme, prognostik yaklaşım için model geliştirme ve tahminlerin yapılması aşamalarından oluşur. Verilerin toplanması aşamasında, sistemin sağlık durumunu temsil eden veriler sensör ölçümleri veya hesaplanmış parametreler kayıt altına alınır. Veri ön işleme aşamasında, veriler temizlenir, normalleştirilir ve eksik veriler tamamlanır. Modelin geliştirilmesi aşamasında, makine öğrenimi veya derin öğrenme algoritmaları kullanılarak bir prognostik model oluşturulur. Tahminlerin yapılması aşamasında ise, geliştirilen model kullanılarak sistemin gelecekteki sağlık durumu tahmin edilir. Veri tabanlı yöntemler, genellikle fizik tabanlı yöntemlere göre daha kolay uygulanabilir. Ancak, etkili bir veri tabanlı prognostik yaklaşımdan verim alabilmek için uçakların uzun uçuş saatlerine sahip olmaları ve ciddi bir operasyon geçmişi ile sistemlerden toplanan verilerin yeterli büyüklükte olması gerekmektedir. Özellikle sivil havacılık sektöründe faaliyet gösteren lider firmaların, örneğin Airbus ve Boeing'in uçaklarına ait kapsamlı operasyon geçmişleri, bu gerekliliği karşılamak adına zengin bir veri kaynağı sunmaktadır.

Hibrit tabanlı prognostik yöntem ise fizik tabanlı ve veri tabanlı yöntemleri birleştirir. Bu yöntem, fizik tabanlı modelin geliştirilmesi, sisteme ait verilerin toplanması, veri ön işleme, sisteme ait verilerin fizik tabanlı modele entegre edilmesi, fiziksel modelin simülasyonu ve elde edilen verilerin toplanması ve işlenmesi sonrası makine öğrenimi veya derin öğrenme algoritmalarına girdi olarak sağlanması ile sağlık durumu tahmini yapılması aşamalarını içerir. Hibrit tabanlı yöntemler genellikle fizik tabanlı ve veri tabanlı yöntemlere kıyasla daha yüksek performans sergiler. Ancak, bu yöntemlerin dezavantajlarını beraberinde getirir. Havacılık sektöründe, uygulama karmaşıklığı ve maliyet fazlalığı nedeniyle kritik sistemler hariç genellikle tercih edilmemektedir. Prognostik yaklaşımda hangi yöntemin kullanılacağı, sistemin özelliklerine ve uygulamanın gereksinimlerine bağlıdır. Fizik tabanlı yöntemler, yüksek doğruluk ve güvenilirlik gerektiren durumlarda tercih edilirken, veri tabanlı yöntemler genellikle kolay uygulanabilirlikleri nedeniyle tercih edilir. Hibrit tabanlı yöntemler ise her iki yaklaşımın avantajlarını birleştirmek için kullanılır.

### 2.1.1 RUL Tanımı

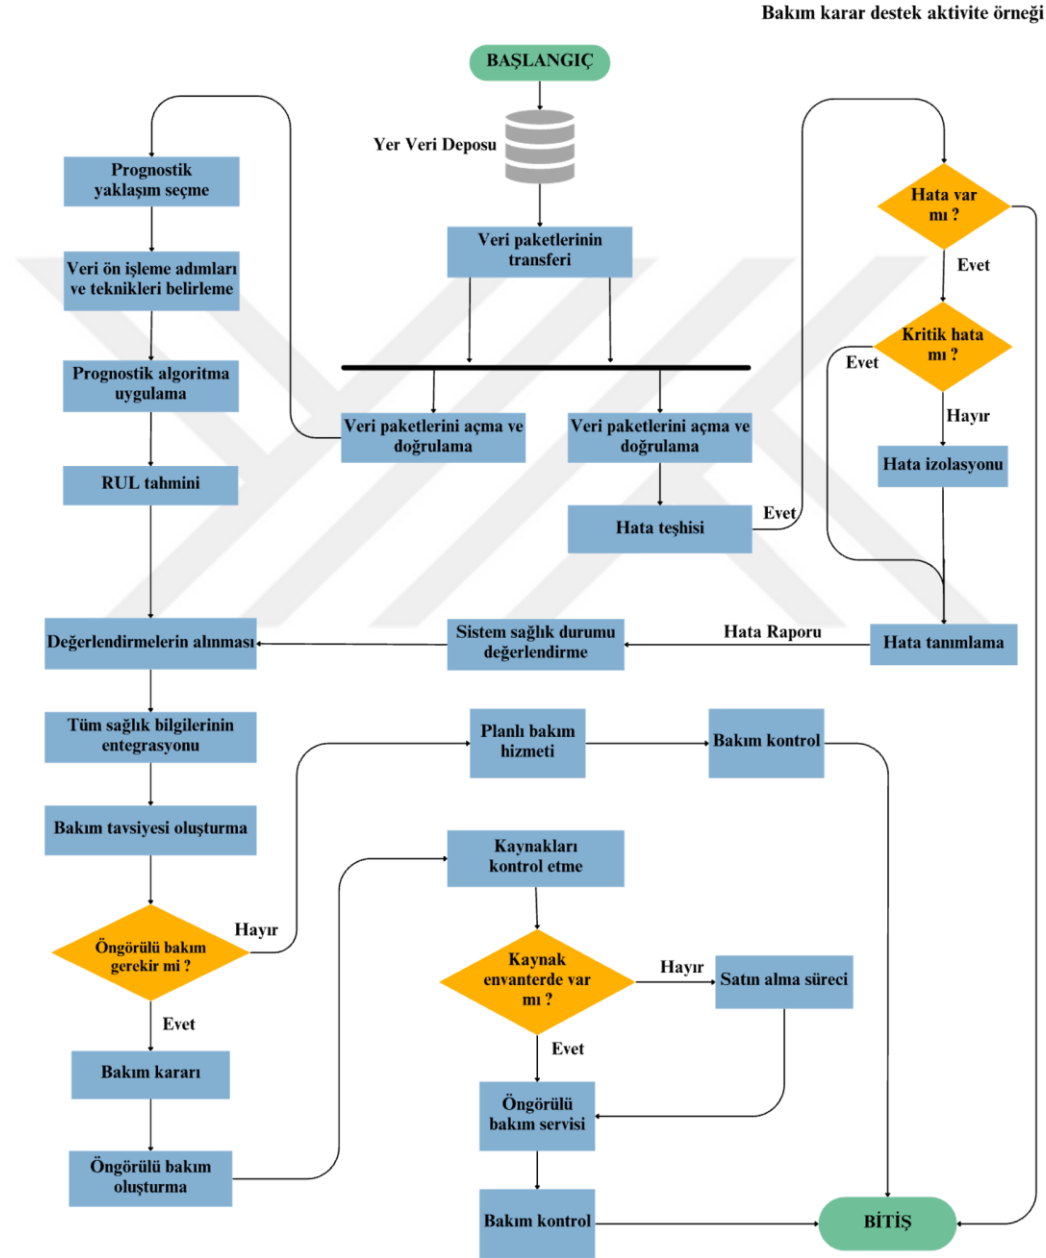
RUL, bir sistem veya ekipmanın mevcut durumunda ne kadar süre daha çalışabileceğini belirten bir ölçümdür. RUL, genellikle zaman birimi cinsinden ifade edilir ve sistem bakım veya değişim ihtiyacı duymadan önce ne kadar süre daha işlevsel olacağını gösterir [44]. **Şekil 2.4**'de bir ekipmanın performansının zaman içerisinde gösterdiği değişim, öngörücü bakım planlama ve RUL ilişkisi gösterilmiştir.



**Şekil 2.4** Bir ekipman veya sistemin degradasyonu ve RUL ile ilişkisi [57]

RUL tahmini, bir sistem veya ekipmanın kullanılabilir ömrünü öngörmek için veri analizi ve öngörü modellerini kullanma sürecidir. Bu tahmin, genellikle cihazın çalışma koşulları, sıcaklık, titreşim, akım gibi parametreleri içeren verilerin toplanması, temizlenmesi ve özellik mühendisliği ile hazırlanmasını içerir. Makine öğrenimi veya derin öğrenme teknikleri kullanılarak geliştirilen modeller, eğitim verileri üzerinde öğrenir ve daha sonra gerçek zamanlı verilerle test edilerek kullanılmaya başlar. RUL tahmini, veri tabanlı, fizik tabanlı ve hibrit tabanlı prognostik yaklaşımlar kullanılarak yapılabilir [44].

Uçak yer operasyonlarında hata durum tespiti ve izolasyonu alanlarında faaliyet gösterilen diagnostik aşaması ile RUL tahmini yapılan prognostik aşamalarının entegre bir şekilde kullanıldığı öngörülen bakım karar alma süreçleri bir aktivite diyagramı örneği ile **Şekil 2.5**'da gösterilmiştir. **Şekil 2.5**, [58]'da verilen PHM akış diyagramı ve havacılık sektöründe edinilen deneyimlerle düzeltmeler yapılarak yeniden kurgulanmıştır.



**Şekil 2.5** Uçak yer operasyonlarında kullanılan bakım karar destek aktivite örneği

[58]

## UÇAK SİSTEMLERİNDE PROGNOSTİK YAKLAŞIMLAR VE UYGULAMALARI

### 3.1 Uçak Motor Sistemi

Uçak motor sistemi, bir uçağın havada hareket etmesi için gerekli olan itme kuvvetini sağlamak üzere tasarlanmış karmaşık bir yapıdır. Uçak motorunun sorumlulukları arasında uçağın havada hareket etmesi için itme sağlamak, yakıt enerjisini mekanik enerjiye çevirmek, temel uçak sistemlerini beslemek, çevresel sürdürülebilirlik için etkili ve az emisyonlu olmayı amaçlamak, uçak güvenliği ve güvenilirliğine kritik bir rol oynamak bulunmaktadır. Havacılıkta, farklı amaçlara hizmet eden çeşitli motor tipleri bulunmaktadır. Turbofan motorları, sivil havacılıkta yaygın olarak kullanılır ve çekirdek bir motoru bir fanla birleştirerek verimliliği artırır. Kompleks alt bileşenlere sahip bir turbofan motora ait görsel **Şekil 3.1**'de verilmiştir. Turbojet motorları, yüksek itme, hız ve manevra kabiliyeti sağlamak için savaş jetlerinde kullanılır. Turboprop motorları, bir gaz türbini ile pervaneyi birleştirerek kısa mesafe uçuşlar için uygundur, turboshaft motorları ise helikopterler gibi döner kanatlı uçakları güçlendirir.



**Şekil 3.1** Turbofan uçak motoru [59]

Uçak motorlarının prognostik yaklaşımlarının analizi için yaygın olarak kullanılan veri setlerinden biri, Commercial Modular Aero-Propulsion System Simulation (C-MAPSS) veri setidir. NASA tarafından geliştirilen C-MAPSS simülatörü, gerçekçi büyük ticari turbofan motor verilerinin simülasyonu için özel olarak tasarlanmış bir araçtır. Bu simülatör aracılığıyla üretilen ve paylaşılan veri seti, uçak motorlarının prognostik yaklaşımları için literatürde yaygın olarak kullanılmıştır. C-MAPSS, farklı işletme koşullarını modelleyen dört farklı alt-veri setinden oluşur ve her biri bir dizi sensör verisi içerir. Bu sensör verileri, motorun çeşitli performans ve sağlık parametrelerini yansıtarak, makine öğrenimi ve veri analizi teknikleriyle kullanılarak prognostik modellerin geliştirilmesi için kullanılır. C-MAPSS veri seti, uçak motorlarının ömrü boyunca oluşabilecek değişiklikleri ve arızaları modelleyen gerçekçi bir ortam sağlamak amacıyla tasarlanmıştır. Bu veri seti üzerinde yapılan çalışmalar, uçak endüstrisinde öngörücü bakım stratejilerini geliştirmeye ve uçak motorlarının güvenilirliğini artırmaya yönelik önemli bilgiler sunmaktadır.

Bu veri seti üzerinde yapılan çalışmalarda kullanılan prognostik yaklaşımları inceleyebiliriz. Örneğin bir çalışmada [9], RUL tahmini için veri tabanlı bir yaklaşım uygulanmıştır. LSTM ve CNN birleştirilerek oluşturulan bir derin öğrenme modeli ile RUL tahmini yapılmış ve C-MAPSS veri setinde bulunan doğrulama verileri ile model performansı doğrulanmıştır. Deneysel sonuçlar, LSTM ve CNN modellerinin birleşiminin geleneksel LSTM yapılarına göre daha yüksek doğruluk sağladığı belirtilmiştir. Kıyaslama, kök ortalama kare hatası (RMSE) değerleri üzerinden yapılmıştır.


Bir çalışmada ise [8], fizik tabanlı ve veri tabanlı modellerin ayrı ayrı sınırlamalarını ele alarak karmaşık sistemlerde RUL tahmini için bir hibrit çerçeve önermiştir. Bu yenilikçi yaklaşım, fizik tabanlı performans modellerini sensör verileri ile birleştirerek, veri odaklı tahminler için fizik destekli özelliklere sahip bir derin sinir ağı kullanmıştır. Çalışma, fizik tabanlı ve veri odaklı yaklaşımların birleştirilmesinin her iki yöntemin avantajlarından yararlanarak performans artışına neden olduğunu vurgulamıştır.

Bir diğer çalışmada ise [60], turbofan motorları için RUL tahminine yönelik mevcut yaklaşımlar açıklanmıştır ve fizik tabanlı yöntemlerin karmaşık motor yapısı nedeniyle sınırlamalara sahip olduğundan bahsedilmiştir. Çalışmada veri tabanlı yaklaşım benimsenerek, derin öğrenme modellerinden CNN ve LSTM teknikleri

kullanılarak RUL tahmini yapılmıştır. Ayrıca, veri ön işleme teknikleri kullanılarak derin öğrenme modelinin eğitim hızını ve doğruluğunu artırdığı kanıtlanmıştır.

### 3.2 Uçak Yapısalları

Uçak yapısalları, bir uçağın ana bileşenlerini oluşturan ve uçağın şeklini, yapısını ve gücünü sağlayan bileşenlerdir. Bu yapısal bileşenler, uçağın dayanıklılığını, performansını, aerodinamik özelliklerini ve güvenilirliğini belirleyen önemli faktörlerdir. Uçaklardaki temel yapısal Şekil 3.2’ de gösterilmiştir.



Şekil 3.2 Uçakların temel yapısalı [61]

Uçaklardaki yapısal bileşenlerin sağlık parametresi genellikle yorgunluk hasarı veya çatlaklar biçimindedir. Uçaklar, uçuş sırasında sürekli olarak yüklere maruz kalırlar. Bu yükler, yapısal bileşenlerde yorgunluk hasarına neden olabilir. Yorgunluk hasarı, bir yapının tekrarlanan yüklere maruz kaldığında, yapıdaki atomik bağların kopmasına neden olan bir süreçtir. Yorgunluk hasarı, sonunda yapının çökmesine neden olabilir. Uçaklardaki yapısal bileşenlerde çatlaklar da yaygın bir sorundur. Çatlaklar, yapısal bileşenlerde mekanik bir darbe veya


korozyon gibi çeşitli nedenlerle oluşabilir. Çatlaklar, yapının gücünü ve sertliğini azaltır ve bu da sonunda yapının çökmesine neden olabilir.

Uçak yapılarının zaman içindeki yıpranmalarını veya olası hasarları tespit etmek ve kalan kullanım ömrünü tahmin edebilmek amacıyla Yapısal Sağlık İzleme (SHM) süreci uygulanmaktadır [62], [63]. SHM sistemleri, yapısal bileşenlerde hasar tespit etmek ve RUL tahmini için, uzun uçuş saatleri boyunca kaydedilen sensör ölçüm verilerini kullanır. Sensor tiplerine örnek vermek gerekirse; akselerometreler, yapısal titreşimleri ölçerken; gerilme ölçerleri (strain gauges), malzemelerdeki gerilmeleri izler. Akustik sensörler, olası hasarları ses sinyalleri üzerinden tespit ederken; manyetik sensörler, metal yapıların deformasyonlarını algılar. Termal sensörler, sıcaklık değişikliklerini izler ve yapıdaki anormallikleri belirleyebilir. Yük hücreleri (load cells), uygulanan kuvvetleri ölçer. Bu sensörler aracılığıyla toplanan veriler işlenerek, veri tabanlı, fizik tabanlı ve hibrit tabanlı prognostik yaklaşımlar kullanılarak benzer şekilde RUL tahmini yapılabilir.

### **3.3 Elektrik Güç Sistemleri**

Elektrik güç sistemi, uçağın güvenli ve verimli bir şekilde uçabilmesi için kritik öneme sahip bir sistemdir. Bu sistem, uçağın tüm sistem ve ekipmanlarına, örneğin, aviyoniklere, aydınlatma sistemlerine, iletişim sistemlerine ve çevresel kontrol sistemlerine elektrik gücü üretme, dağıtma ve yönetme sorumluluğundadır.

Uçak elektrik güç sistemi, alt sistem olarak çeşitli üniteler ve ekipmanlardan oluşur. Boeing 787 uçağına ait elektrik güç sistemi ve alt sistemleri **Şekil 3.3**'de gösterilmiştir.



**Şekil 3.3** Boeing 787 elektrik güç üretim ve dağıtım sistemi [64]

Literatürde genellikle prognostik yaklaşımın uygulandığı üniteler veya ekipmanlar arasında elektrik gücü üretilmesini sağlayan yardımcı güç ünitesi (APU) ve güç dağıtım sisteminde kullanılan DC-DC dönüştürücülere örnek verilebilir.

APU, uçak motorları çalışmadığında elektrik gücü sağlamak için tasarlanmış küçük, bağımsız bir güç üreticidir. APU, genellikle uçak motorlarını çalıştırmak, taksi ve yer operasyonları sırasında güç sağlamak ve uçakta bulunan elektronik sistemleri çalıştırmak için kullanılır. APU için uygulanan prognostik yaklaşımlara örnek olarak, [13] çalışmasında, APU'nun RUL tahmininde veri tabanlı ve fizik tabanlı yaklaşımın birleşimi olan hibrit tabanlı yaklaşım önerilmiştir. Çalışma, Çin havayolu şirketi bakım üssünden elde edilen gerçek egzoz gazı sıcaklığı (EGT) verileri kullanılarak ve matematiksel veya fiziksel model yaklaşımı ile üretilen veriler entegre edilerek LSTM modeline girdi olarak sağlanmıştır.

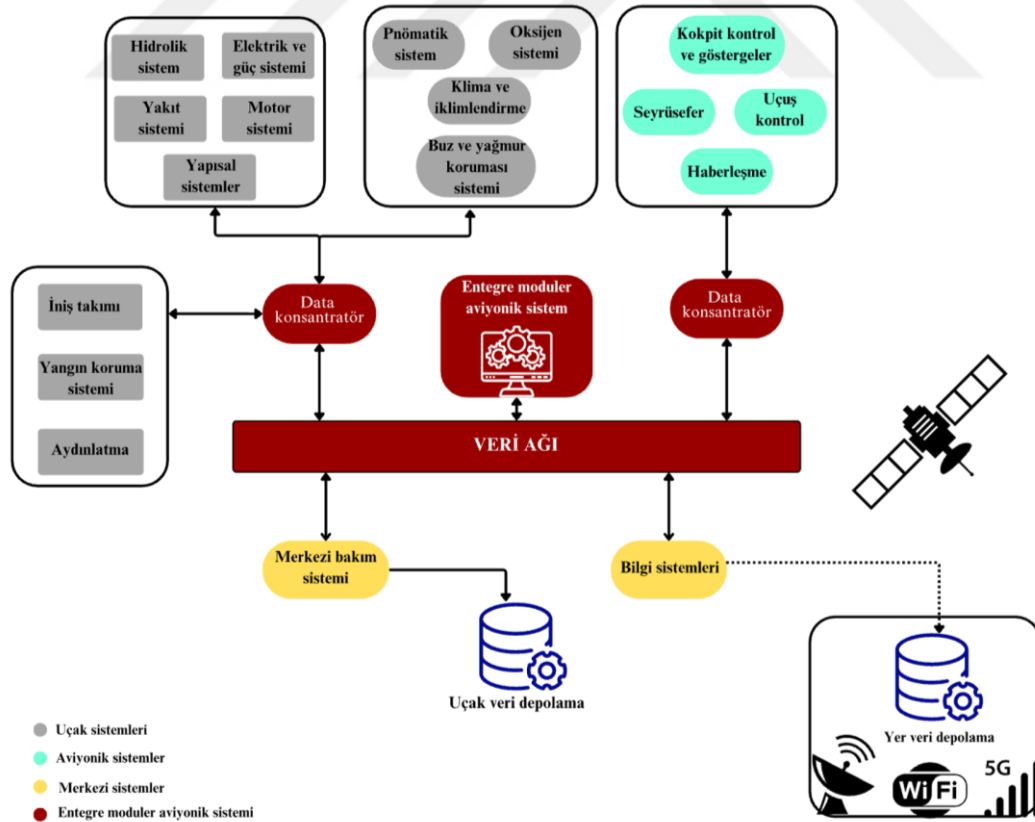
Uçaklarda, DC-DC dönüştürücü ise, bir elektrik akımını bir gerilim seviyesinden diğerine dönüştüren bir elektronik cihazdır. Bu dönüştürücüler, uçak elektrik sistemlerinde güç dağıtımını ve yönetimini optimize etmek için kullanılır. Bir çalışmada [14], DC-DC dönüştürücülerin performans ve sağlık parametreleri, HI olarak kullanılmıştır ve veri tabanlı prognostik yaklaşım benimsenerek, derin öğrenme modeli olan LSTM ile RUL tahmini yapılmıştır. Modelin performansını değerlendirmek için RMSE, ortalama mutlak hata (MAE) ve ortalama mutlak yüzde

hata (MAPE) gibi ölçütler kullanılmıştır. Yapılan kıyaslama analizi, literatürde daha önce uygulanmış diğer derin öğrenme modelleri arasında yapılarak, CNN, RNN, Kapılı Tekrarlayan Birim (GRU) ve LSTM'in incelenmesi sonucunda, en yüksek doğruluğa LSTM modelinin sahip olduğu kanıtlanmıştır.

### 3.4 Aviyonik Sistemler

Aviyonik, uçaklar ve diğer hava araçlarında kullanılan elektronik sistemleri ifade eder. Bu sistemler, uçağın kontrolünü, haberleşmesini, konum bildirimini ve diğer önemli işlevlerini sağlar. Temel aviyonik sistemler arasında uçuş kontrol sistemleri, seyrüsefer sistemleri, haberleşme sistemleri, gösterge ve kontrol sistemleri bulunur. Bu sistemler genellikle birbirleriyle entegre edilmiş ve bir ağ üzerinden iletişim kurarak uçağın güvenli bir şekilde uçuşmasını sağlar.

Aviyonik sistemlerin de yer aldığı merkezi bir uçak mimarisini Şekil 3.4' deki gibi basitçe gösterebiliriz.




Şekil 3.4 Uçak mimarisine genel bir bakış

Aviyonik sistemler, diğer uçak sistemleri gibi çeşitli sensörler, çalışma verileri ve sağlık parametreleri ile donatılmıştır. Bu sensörler, uçaklardaki aviyonik sistemlerde kritik bir rol oynar. Uçağın durumunu, konumunu, çevresel koşulları ve diğer önemli parametreleri sürekli olarak izleyerek, uçuş kontrol sistemlerine, diğer alt sistemlere ve pilotlara geri bildirim veya uyarı sağlar. Örneğin, hız ve irtifa sensörleri, uçağın stabilizesini ve manevra yeteneklerini kontrol etmek için kullanılırken, GPS ve seyrüsefer sistemleri, uçağın hassas konumunu belirlemek ve doğru bir şekilde yönlendirmek amacıyla kullanılır. Bu kritik veriler aynı zamanda sistemin sağlık durumunu da belirtmesinden dolayı, uçaktaki ortak veri ağı üzerinden merkezi bakım sistemine iletilir ve gerekli kayıt işlemleri uçuş sırasında gerçekleştirilir. Uçuş boyunca kaydedilen veriler, uçak yere indiğinde bilgi sistemleri aracılığıyla yer veri depolarına transfer edilir. Bu süreçte, diğer uçaklardan veya farklı uçaklardan gelen verilerle birleştirilerek büyük veri depolarında saklanır.

Prognostik yaklaşım, diğer uçak veya yapısal sistemlerde olduğu gibi, veri bilimi teknikleriyle yer operasyonlarının bir parçası olarak uygulanır. Prognostik yaklaşımın, özellikle askeri havacılıkta, yani savaş jetlerinin kullanıldığı alanda hayati bir öneme sahip olduğu göz önüne alındığında, aviyonik sistemlerin öngörücü bakıma tabi tutulması zorunluluğu ortaya çıkmaktadır. Savaş jetleri, son derece gelişmiş teknolojilere ve sofistike silah sistemlerine sahiptir. Bu ileri seviye aviyonik sistemlerinin yerde bakım optimizasyonunun öngörücü bakım kapsamında planlanması, özellikle maliyet açısından kritik bir faktördür. Zira bu sistemler, sadece yüksek maliyetli değil aynı zamanda stratejik öneme sahip oldukları için herhangi bir arıza veya kayıp ciddi zararlara yol açabilir. Prognostik yaklaşımın kullanılması, aviyonik sistemlerin gelecekteki arızalarını tahmin etmeye ve bakım ihtiyaçlarını önceden belirlemeye olanak tanır. Ayrıca, askeri havacılıkta güvenilirlik ve hazırda bulunma durumu, stratejik bir avantajdır.

Aviyonik sistemlerin prognostik yaklaşımına dair yapılmış çeşitli literatür çalışmaları bulunmaktadır. Aviyonik sistemler, temelini oluşturan elektronik bileşenlere dayandığından, özellikle elektronik bileşenlerin RUL tahmini ve prognostik yaklaşımına odaklanan detaylı araştırmalar yapılmıştır. Bu çalışmalar, aviyonik sistemlerin performansını optimize etme, bakım süreçlerini iyileştirme ve uçuş güvenliğini artırma amacını taşımaktadır.

Bir çalışmada [65], GPS için fizik tabanlı prognostik yaklaşım ile RUL tahmininin nasıl yapıldığı açıklanmıştır. Tipik bir GPS alıcısının temel elektronik bileşenleri incelenmiştir (ör. **Şekil 3.5** [66]). Çalışmada, aviyonik sistemlerde fizik tabanlı prognostik yaklaşım için hata durumu ve etki analizi (FMEA) kullanılarak GPS sağlık parametreleri çıkartılmıştır ve belirlenmiştir. FMEA dan yola çıkarak, elektronik ekipmanlar için, devreleri yüksek frekanslı analog, düşük frekanslı analog, düşük empedans ve yüksek empedans devreleri olarak sınıflandırmıştır. Yüksek frekanslı analog devrelerdeki arıza mekanizmalarının genellikle operasyonel olduğu, düşük frekanslı analog devrelerin ise daha çok fiziksel cihaz arızalarına eğilimli olduğu vurgulanmıştır. GPS alıcısı üzerinde yapılan uygulama, özellikle yüksek frekanslı analog devrelerin, örneğin MOSFET'lerin, kullanıldığı bir senaryoyu içermiştir. Bu uygulama, hızlandırılmış arıza testi ile belirlenen bu sağlık parametreleri kullanılarak RUL tahmini yapılmıştır.



**Şekil 3.5** GPS alıcı örneği (The Rockwell Collins GB-GRAM-M)

Bir başka çalışmada [15], radar sistemlerinin karmaşık ve yüksek performanslı sistemler olduğu ve bu sistemlerin performansını ve güvenilirliğini sürdürmek için etkili bir bakım stratejisinin gerekliliği vurgulanmıştır. Bu makalede, radar sistemleri için özel olarak tasarlanmış aşamalı PHM çerçevesi sunulmaktadır. Çerçeve, radar sistemlerini genel sistem, alt sistem ve cihaz düzeyi hiyerarşilerine göre ele alan bir PHM yaklaşımını içermektedir. Bu yöntemle, sistem sağlığının kapsamlı bir şekilde izlenmesi ve bakım kararlarının daha doğru bir şekilde

verilmesi hedeflenmektedir. Uygulama kısmında ise, LSTM modeli ile RUL tahmininin başarıyla gerçekleştirildiği kanıtlanmıştır.


Bir başka çalışmada ise [16], seyrüsefer sistemlerinde kritik rolü olan jiroskopların RUL tahmini incelenmiştir. Jiroskoplar için RUL tahmininin yapılması, verimliliğini, güvenilirliğini artırmak ve aynı zamanda bakım maliyetlerini azaltmak için son derece önemli olduğu vurgulanmıştır. Jiroskopun zamana bağlı sapma hızını sağlık parametresi olarak kullanan veri tabanlı bir prognostik yaklaşım önerilmiştir. Simülasyonla elde edilmiş veriler kullanılarak LSTM modeli ile deneysel doğrulama yapılmıştır.



# CMAPSS UÇAK MOTORU VERİLERİ İÇİN VERİ TABANLI PROGNOSTİK UYGULAMASI

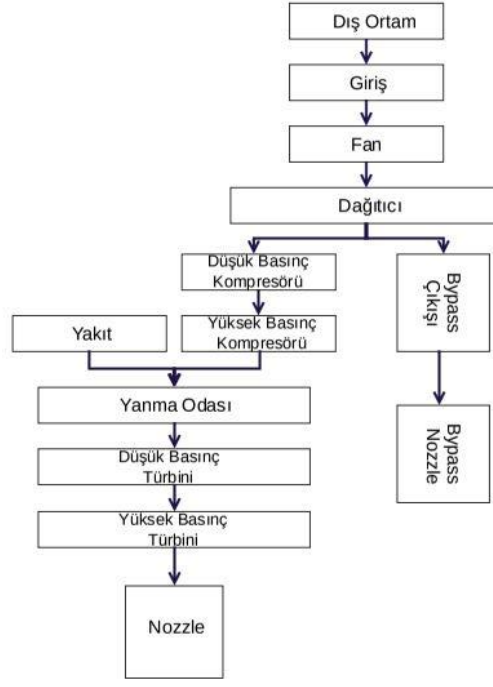
## 4.1 CMAPSS Veri Seti

C-MAPSS, "Commercial Modular Aero-Propulsion System Simulation"ın kısaltmasıdır ve ticari uçak motorları için geliştirilmiş bir simülasyon aracını ifade eder. Bu araç, NASA (National Aeronautics and Space Administration) tarafından geliştirilmiştir. C-MAPSS, ticari büyük turbofan motorlarının davranışlarını modellemek için tasarlanmış bir araçtır. Bu simülasyon, motorların performansını, aşınma durumlarını, arızalarını ve farklı uçuş koşullarındaki tepkilerini modelleyebilir. Bu yazılım aracı ile üretilen C-MAPSS veri seti, NASA aracılığı ile açık veri portalı üzerinden paylaşılmıştır. "Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation", adlı çalışma da veri seti ile birlikte paylaşılmıştır. Bu çalışmada, C-MAPSS veri setinin nasıl üretildiği, motor modeli ve parametreleri açıklanmıştır [67]. **Şekil 4.1**'de modellenen motora ait temel yapılar, bileşenler ve aralarındaki akış gösterilmiştir.



a)

**Şekil 4.1 a)** C-MAPSS yazılımında modellenmiş uçak motoruna ait basitleştirilmiş şema **b)** bileşenler arasındaki akış modeli



b)

**Şekil 4.1 a)** C-MAPSS yazılımında modellenmiş uçak motoruna ait basitleştirilmiş şema **b)** bileşenler arasındaki akış modeli (devamı)

Fan, uçağa önden baktığımızda gördüğümüz motora ait ilk yapıdır. Motor çalıştığında fan dönmeye başlar ve havayı bükerek içeri alır. İtki kuvveti oluşturmak için olmazsa olmazlardan biri de havadır. Hava kompresörlere doğru içeri hareket eder. Kompresörler, havayı sıkıştırma aşamasında rol alır. Sıkıştırma aşaması, yanma aşamasında havanın tutuşması için doğru basınç ve sıcaklık olmasını sağlar. Havanın yüksek basınçlı hale gelmesine ve daha yüksek termal enerjiye sahip olmasına neden olur. Sıkıştırılan hava daha sonra yanma odasına doğru hareket eder ve burada yakıtla karşılaşır. Yanma odasında hava ve yakıtın yanması sağlanır. Yanan hava yanma odasından çıkarken türbine girer. Yüksek hızlı sıcak hava türbinden geçerken havadan ek enerji emerek türbinin tamamen dönmesine ve kendisine bağlı motor şaftını döndürmesini sağlar. Türbin şaftı da fan ve kompresöre bağlıdır. Türbin döndükçe turbofan motorunun önündeki kompresör ve fanlar daha fazla hava emmeye devam eder ve hızla yakıtla karışır ve yanar. Böylece uçak için en önemli kuvvetlerden biri olan itki gücü oluşmuş olur [67].

C-MAPSS veri seti dört farklı alt veri setinden oluşur: FD001, FD002, FD003 ve FD004. Her biri farklı motor tiplerini ve hata durumlarını temsil eder. FD001, birinci tip motoru ve özellikle yüksek basınç kompresörü (HPC) ve fan hata durumlarını içerir. FD002, ikinci tip motorun hata durumlarına odaklanırken, FD003 ve FD004 sırasıyla üçüncü ve dördüncü tip motorları temsil eder. Bu veri setleri, motorların sağlık durumunu değerlendirmek, hata durumlarına karşı duyarlılığı incelemek ve prognostik algoritmalarını geliştirmek amacıyla kullanılmaktadır. Her bir veri seti, motor modelleri, hata durumları, operasyonel koşullar, sağlık parametreleri ve zaman adımı gibi detayları içerir. FD002, FD003 ve FD004, benzer şekilde tasarlanmış olup, belirli hata durumlarını modelleyerek motorların performansını değerlendirmeyi amaçlar. FD001 veri setinde bulunan verilere ilişkin bilgiler **Tablo 4.1**'de gösterilmiştir [67].

**Tablo 4.1** FD001 veri setinde bulunan veriler ve etiketleri

Veri etiketi	Sembol	Açıklama	Birim
unit_ID	-	Motor Birim Numarası [1-100]	-
cycles	-	Zaman adımı	t
setting_1	-	İrtifa	ft
setting_2	-	Mak Sayısı	M
setting_3	-	Deniz seviyesi sıcaklık	°F
sensor_1	T2	Fan girişindeki toplam sıcaklık	°R
sensor_2	T24	Düşük basınç kompresör (LPC) çıkışındaki toplam sıcaklık	°R
sensor_3	T30	Yüksek basınç kompresör (HPC) çıkışındaki toplam sıcaklık	°R
sensor_4	T50	Düşük basınç türbin (LPT) çıkışındaki toplam sıcaklık	°R

**Tablo 4.1** FD001 veri setinde bulunan veriler ve etiketleri (devamı)

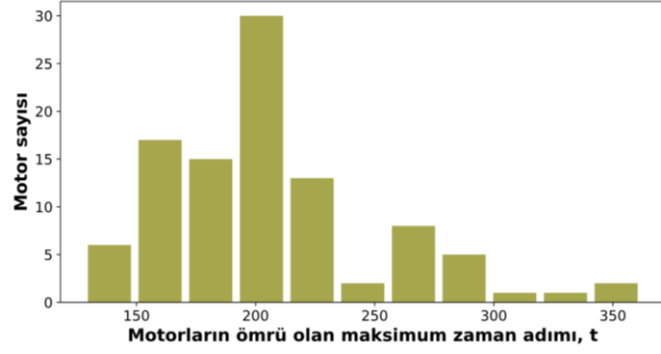
sensor_5	P2	Fan girişindeki basınç	psia
sensor_6	P15	Baypas kanalındaki toplam basınç	psia
sensor_7	P30	HPC çıkışındaki toplam basınç	psia
sensor_8	Nf	Fiziksel fan hızı	rpm
sensor_9	Nc	Fiziksel çekirdek hızı	rpm
sensor_10	epr	Motor basınç oranı	-
sensor_11	Ps30	HPC çıkışındaki durağan basınç	psia
sensor_12	phi	Ps30 un yakıt akışına oranı	pps/psi
sensor_13	NRf	Düzeltilmiş fan hızı	rpm
sensor_14	NRc	Düzeltilmiş çekirdek hızı	rpm
sensor_15	BPR	Bypas oranı	-
sensor_16	farB	Yanan yakıt-hava oranı	-
sensor_17	htBleed	Tahliye entalpisi	-
sensor_18	Nfdmd	Talep edilen fan hızı	rpm
sensor_19	PCNfR dmd	Talep edilen düzeltilmiş fan hızı	rpm
sensor_20	W31	Yüksek basınç türbin (HPT) soğutma tahliyesi	Ibm/s
sensor_21	W32	LPT soğutma tahliyesi	Ibm/s

FD001 eğitim verisinin boyutu 20631 satır ve 26 sütundan oluşurken, test verisi 13096 satır ve 26 sütundan oluşmaktadır. Her satır, tek bir zaman adımında alınan sensor verilerinin anlık görüntüsüdür. NASA tarafından, özellikle sensor verilerinin gürültülü şekilde sağlandığı belirtilmiştir. **Tablo 4.1**'de verilen parametreler, eğitim ve test veri setinde aynı olarak ifade edilmiştir [68]. **Şekil 4.2**'de eğitim veri setine ait satır ve sütunların sadeleştirilmiş görüntüsü verilmiştir.


	unit_ID	cycles	setting_1	setting_2	setting_3	sensor_1	sensor_2	sensor_3	sensor_4	sensor_5	sensor_16	sensor_17	sensor_18	sensor_19	sensor_20	sensor_21
1																
2	1	1	-0,0007	-0,0004	100	518,67	641,82	1589,7	1400,6	14,62	0,03	392	2388	100	39,06	23,419
3	1	2	0,0019	-0,0003	100	518,67	642,15	1591,82	1403,14	14,62	0,03	392	2388	100	39	23,4236
4	1	3	-0,0043	0,0003	100	518,67	642,35	1587,99	1404,2	14,62	0,03	390	2388	100	38,95	23,3442
5	1	4	0,0007	0	100	518,67	642,35	1582,79	1401,87	14,62	0,03	392	2388	100	38,88	23,3739
6	1	5	-0,0019	-0,0002	100	518,67	642,37	1582,85	1406,22	14,62	0,03	393	2388	100	38,9	23,4044
7	1	6	-0,0043	-0,0001	100	518,67	642,1	1584,47	1398,37	14,62	0,03	391	2388	100	38,98	23,3669
8	1	7	0,0001	0,0001	100	518,67	642,48	1592,32	1397,77	14,62	0,03	392	2388	100	39,1	23,3774
9	1	8	-0,0034	0,0003	100	518,67	642,56	1582,96	1400,97	14,62	0,03	391	2388	100	38,97	23,3106
10	1	9	0,0008	0,0001	100	518,67	642,12	1590,98	1394,8	14,62	0,03	392	2388	100	39,05	23,4066
11	1	10	-0,0033	0,0001	100	518,67	641,71	1591,24	1400,46	14,62	0,03	393	2388	100	38,95	23,4694
20621	100	189	0,0015	0,0001	100	518,67	643,69	1599,85	1423,15	14,62	0,03	397	2388	100	38,65	23,0591
20622	100	190	-0,0001	0,0002	100	518,67	643,12	1594,45	1426,04	14,62	0,03	395	2388	100	38,42	23,0603
20623	100	191	-0,0005	0	100	518,67	643,69	1610,87	1427,19	14,62	0,03	398	2388	100	38,39	23,1218
20624	100	192	-0,0009	0,0001	100	518,67	643,53	1601,23	1419,48	14,62	0,03	397	2388	100	38,56	23,077
20625	100	193	-0,0001	0,0002	100	518,67	643,09	1599,81	1428,93	14,62	0,03	397	2388	100	38,47	23,023
20626	100	194	-0,0011	0,0003	100	518,67	643,72	1597,29	1427,41	14,62	0,03	394	2388	100	38,38	23,1324
20627	100	195	-0,0002	-0,0001	100	518,67	643,41	1600,04	1431,9	14,62	0,03	394	2388	100	38,14	23,1923
20628	100	196	-0,0004	-0,0003	100	518,67	643,49	1597,98	1428,63	14,62	0,03	397	2388	100	38,49	22,9735
20629	100	197	-0,0016	-0,0005	100	518,67	643,54	1604,5	1433,58	14,62	0,03	395	2388	100	38,3	23,1594
20630	100	198	0,0004	0	100	518,67	643,42	1602,46	1428,18	14,62	0,03	398	2388	100	38,44	22,9333
20631	100	199	-0,0011	0,0003	100	518,67	643,23	1605,26	1426,53	14,62	0,03	395	2388	100	38,29	23,064
20632	100	200	-0,0032	-0,0005	100	518,67	643,85	1600,38	1432,14	14,62	0,03	396	2388	100	38,37	23,0522

**Şekil 4.2** FD001 eğitim veri seti satır ve sütun görüntüsü

**Şekil 4.3 a)**'de verilen grafikte, FD001 eğitim veri setindeki 100 motorun maksimum zaman adımları ve motor sayısı sıklığı ile birlikte göstermektedir. Veri setindeki yaklaşık üç motor 350. zaman adımına kadar çalışabilmiştir. Yaklaşık 30 motor 200. zaman adımında arızalanmış ve çalışmayı durdurmuştur. **Şekil 4.3 b)**'de ise, test veri kümesindeki 100 motorun son çalıştırıldığı zaman adımı ve motor sayısı dağılımını göstermektedir. Motorlar belirli zaman adımına kadar çalıştırılmıştır ve test verileri her motor için bozulmadan çalışabilecekleri maksimum zaman adımları bilgisini içermemektedir. Bu bilgi, test kümesindeki motorlar için gerçek RUL değerleri olarak, FD001 de "RUL" adı ile paylaşılan doğrulama veri seti içerisinde sağlanmıştır [68].



a)



b)

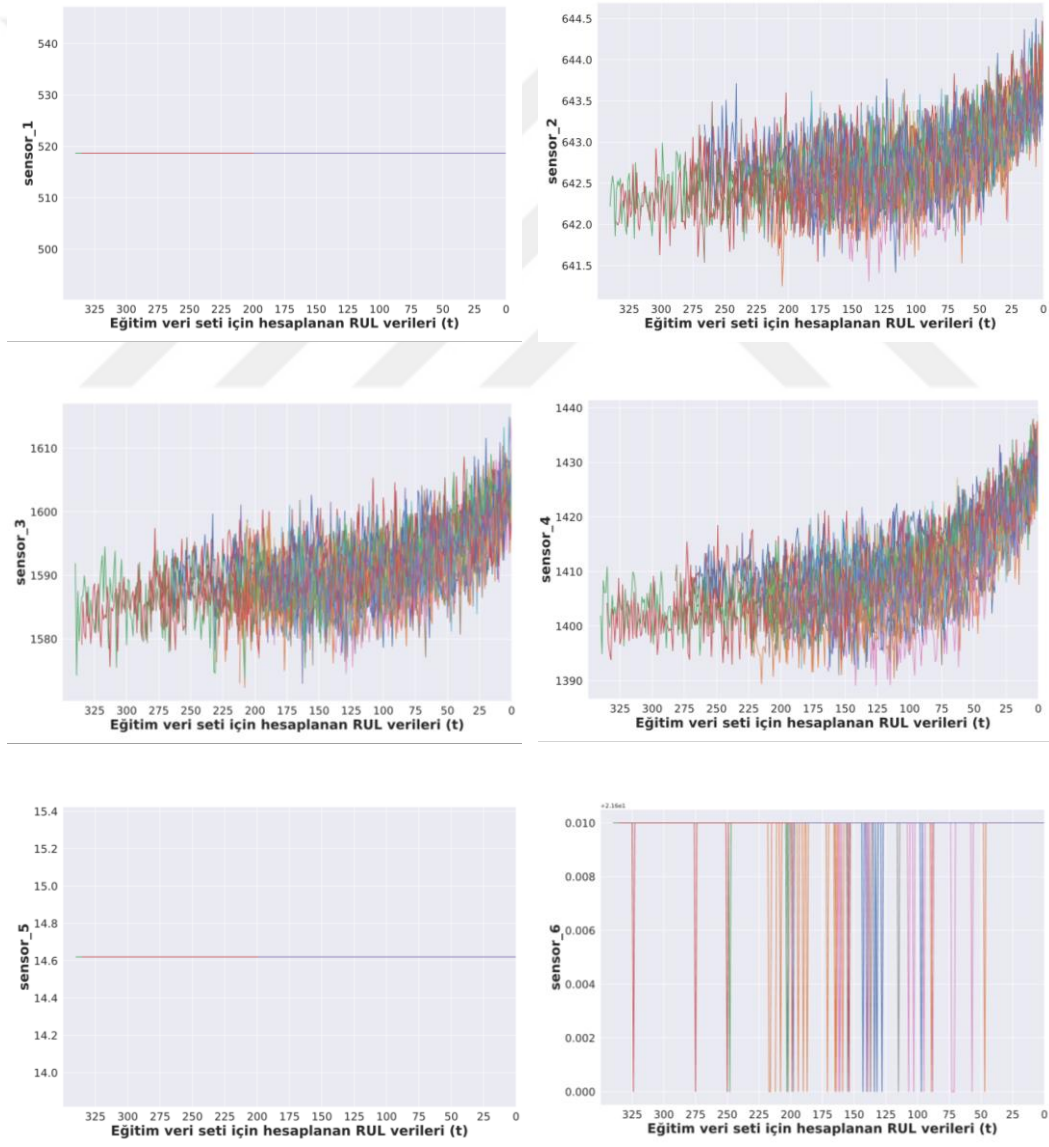
**Şekil 4.3** a) Eğitim veri setindeki motor sayısı ve ulaşılabilen maksimum zaman adımı b) test veri setindeki motor sayısı ve çalıştırıldıkları son zaman adımı ilişkisi

Eğitim veri setinde, her bir motorun sensör verileri, motor ömrünün en son çalışabildiği maksimum zaman adımlarına kadar sağlanmıştır. Bu durum, zaman adımları ile RUL arasında ve bu zaman adımlarına karşılık gelen sensör verileri arasında belirgin bir ilişkiyi göstermektedir. RUL değerleri bu veri setinde (4.1)'deki denklem ile hesaplanır:

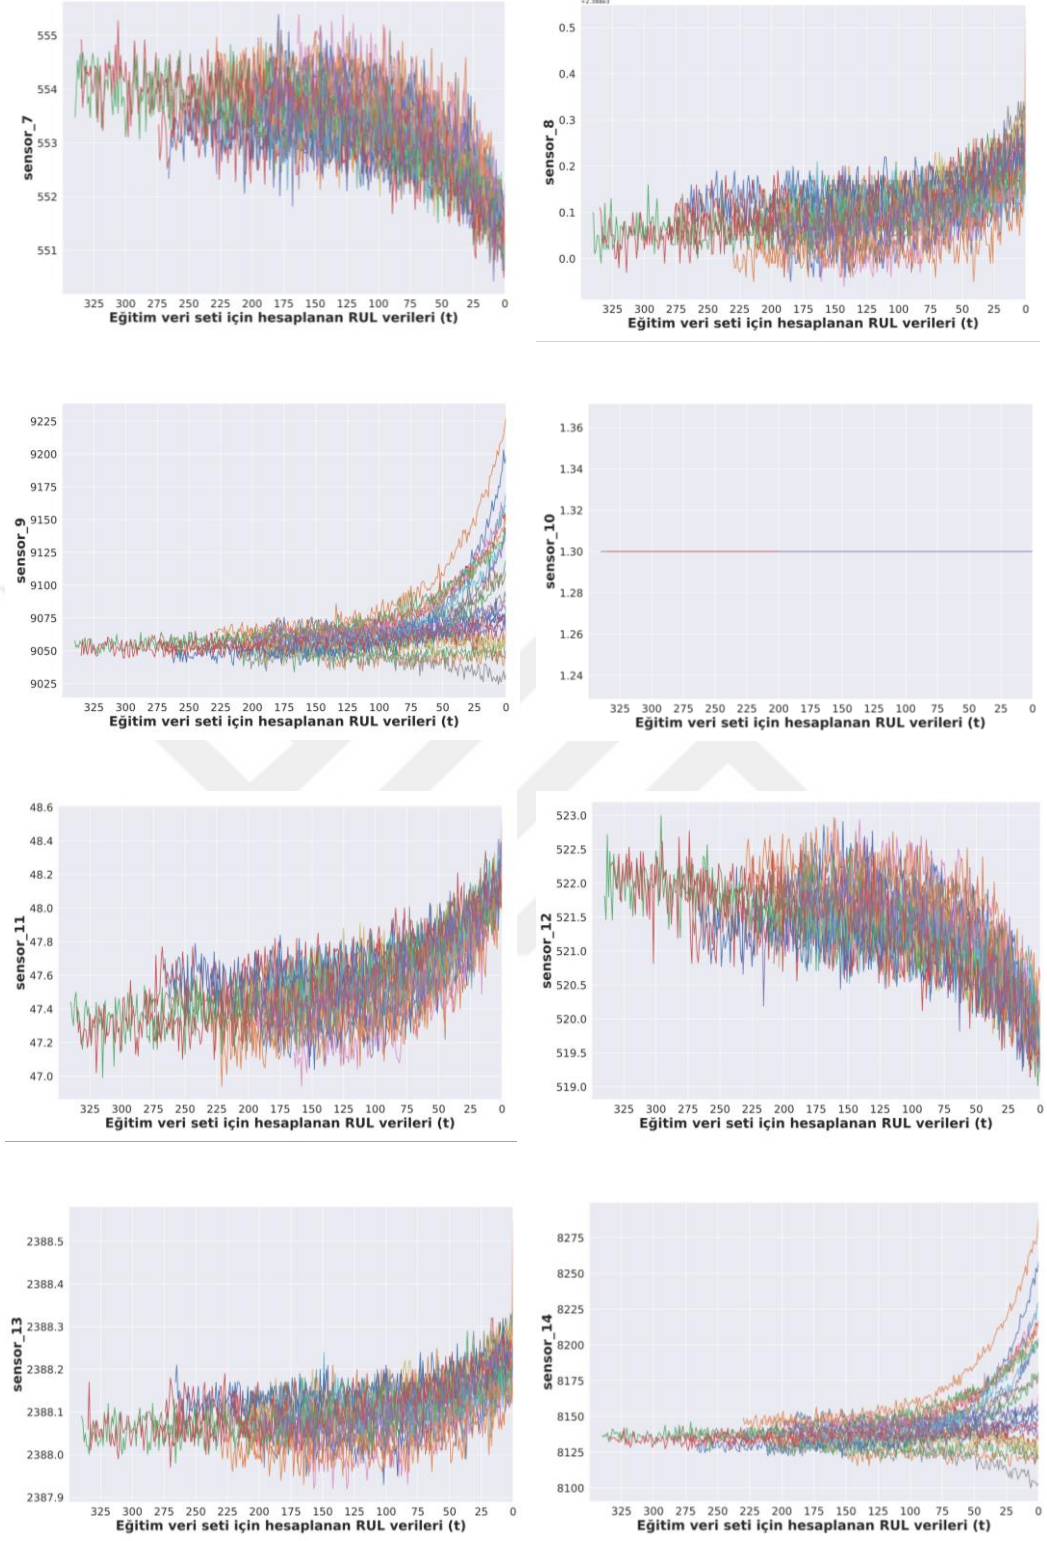
$$RUL(t) = \max(t)_{unitID} - t \quad (4.1)$$

Örneğin, eğitim veri setindeki 1. motor veya unitID '1', 192. zaman adımında bozularak çalışmayı durdurmuştur. Bu durumda, unitID '1', [1, 2, 3, 4, ..., 192] şeklinde 192 zaman adımına ( $t$ ) sahiptir. Motorun  $t = 1$  zaman adımındaki RUL

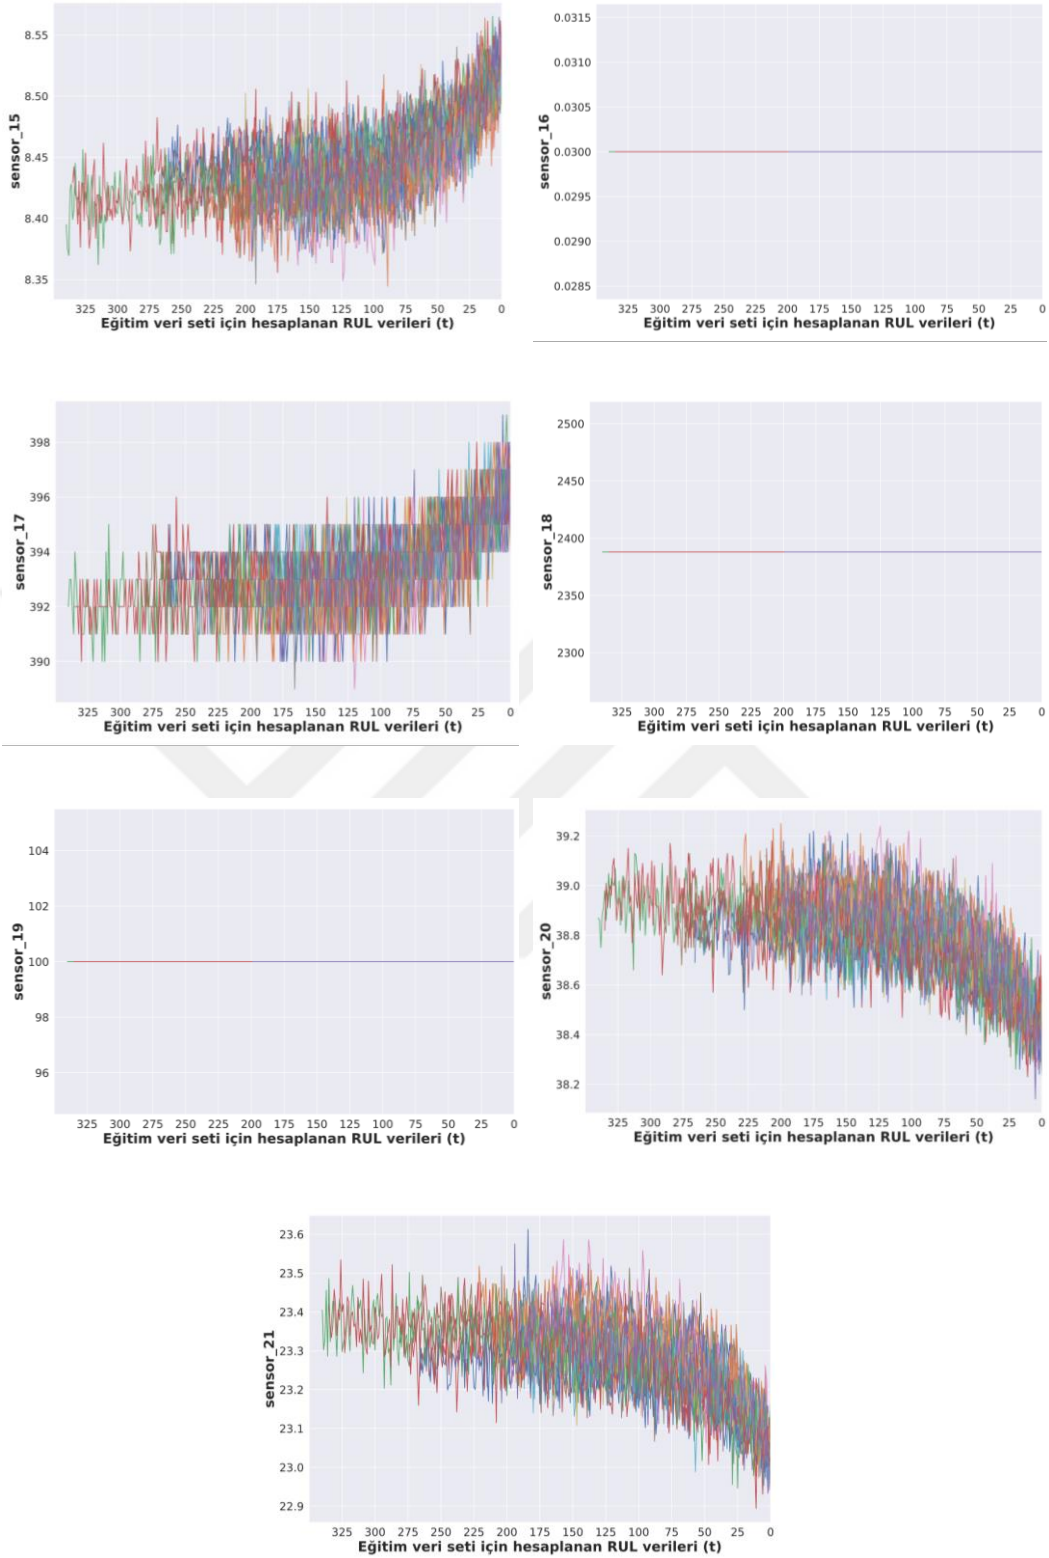
değerini hesaplamak için (4.1) denklemini kullanarak,  $RUL(1) = Max(1)_1 - 1 = 192 - 1 = 191$  elde ederiz. Benzer şekilde, her  $t$  anı için (4.1) denklemi ile bir RUL değeri hesaplanabilir. Motorların bozulmasına doğru ilerleyen zaman adımları için (4.1) denklemi ile hesaplanmış RUL değerleri ile sensör verileri arasındaki ilişki, örnek olarak **Şekil 4.4**'te sırasıyla gösterilmiştir. **Şekil 4.4**, 100 farklı motora ait tüm sensör ölçümlerini içerir ve sensörlerin ölçüm birimleri ise **Tablo 4.1**'de gösterilmiştir. Eğitim veri setinde yer alan motorların çalıştığı maksimum zaman adımlarına kadar ölçülen sensör verileri ve hesaplanan RUL değerleri ile olan ilişki, derin öğrenme modeline girdi olarak verilir. Bu sayede model, RUL ile sensör verileri arasındaki ilişkileri öğrenerek eğitilir.



**Şekil 4.4** Sensor verileri ve hesaplanan RUL değerleri arasındaki ilişki



Şekil 4.4 Sensor verileri ve hesaplanan RUL değerleri arasındaki ilişki (devamı)




Şekil 4.4 Sensor verileri ve hesaplanan RUL değerleri arasındaki ilişki (devamı)

## 4.2 LSTM ve RUL Tahmini

LSTM, zaman serileri ve sıralı veri üzerinde etkili olan bir tekrarlayan sinir ağı (RNN) mimarisidir ve ilk olarak 1997 yılında Hochreiter ve Schmidhuber tarafından tanıtılmıştır [69]. LSTM modelleri, RUL tahmini için etkili bir derin öğrenme modelidir. Bunun nedeni, uzun vadeli bağımlılıkları ele alma, bilgiyi seçici bir şekilde koruma ve karmaşık desenleri öğrenme yetenekleridir. RUL tahmini, bir sistemin bozulma eğilimlerini tahmin etmeyi gerektirir. Bu eğilimler, zaman içinde yavaş yavaş gelişebilir ve bozulma anında önemli bir rol oynayabilir. LSTM modelleri, uzun vadeli bağımlılıkları ele alma yeteneğine sahiptir. Bu, geçmiş verileri kullanarak bozulma eğilimlerini daha iyi anlamaları ve daha doğru tahminler yapmaları anlamına gelir.

LSTM modelleri, hafıza hücreleri ve kapı mekanizmaları kullanarak geçmiş verileri depolayabilir ve işleyebilir. Bu, modelin önemli bilgileri hatırlamasını ve gereksiz bilgileri atmasını sağlar. LSTM yapısal olarak incelendiğinde hücrenin iç yapısına ait gösterim Şekil 4.5’de verilmiştir.



Şekil 4.5 LSTM hücresinin iç yapısının gösterimi

LSTM ağı, bir zaman adımında belirli bir girdiye bağlı olarak birimlerin aktivasyonlarını hesaplar. Bu aktivasyonlar, ağın içindeki kapılar ve hücre durumu tarafından kontrol edilir. LSTM hücrelerinin aktivasyonlarını belirleyen denklemler (4.2)’de verilmiştir.

$$\begin{aligned}
g_t &= \tanh(W_g * [h_{t-1}, x_t] + b_g) \\
i_t &= (W_i * [h_{t-1}, x_t] + b_i) \\
f_t &= \sigma(W_f * [h_{t-1}, x_t] + b_f) \\
o_t &= \sigma(W_o * [h_{t-1}, x_t] + b_o) \\
c_t &= f_t * c_{t-1} + i_t * g_t \\
h_t &= o_t * \tanh(c_t)
\end{aligned} \tag{4.2}$$

LSTM yapısında, giriş kapısı, unutmama kapısı, çıkış kapısı ve hücre aktivasyonu için kullanılan  $i$ ,  $f$ ,  $o$  ve  $c$  dizileri, hücre içerisinde önemli bir role sahiptir. Bu diziler,  $h$  gizli dizisiyle aynı boyutta olup bilgiyi taşırlar.  $W$  terimleri, hücreden kapı dizilerine ait ağırlık matrislerini ifade eder. LSTM yapısının çıkış katmanında ise genellikle  $\tanh$  gibi bir aktivasyon fonksiyonu kullanılır. Bu denklemler, (4.2), LSTM birimlerinin içerisindeki kapıların aktivasyonlarını ve hücre durumunu güncellemesini ifade eder. Bu sayede LSTM ağı, zaman adımları boyunca girdileri işleyerek ilişkilendirmeler yapar ve ardışık veri örüntülerini yakalamak için hafıza mekanizmasını kullanır [69].

#### 4.2.1 LSTM Model Uygulaması

Havacılık sistemlerindeki prognostik yaklaşımlar genellikle veri tabanlı, fizik tabanlı veya her iki yaklaşımın birleşiminden oluşan hibrit metodolojilere odaklanmaktadır. Havacılık sektöründeki yüksek maliyetler ve derin sistem bilgisine duyulan ihtiyaç, özellikle havayolları ve uçak entegrasyonu yapan firmalar için fizik tabanlı veya hibrit yaklaşımları tercih etmeyi zorlaştırmaktadır. Bu sebeple, havacılık sektörüne katkıda bulunmak amacıyla veri tabanlı prognostik yaklaşım üzerine odaklanan bir uygulama gerçekleştirilmiştir. Bu bağlamda, uçak sistemleri ve aviyonik sistemlerde yaygın olarak tercih edilen modellerden biri olan LSTM modeli, NASA tarafından yayımlanan C-MAPSS veri seti üzerinde uygulanmıştır. LSTM modeli, Anaconda Navigator yazılımı kullanılarak Python programlama dili ile Jupyter Notebook 6.5.4 sürümü üzerinde oluşturulmuştur. LSTM modeli oluşturabilmek için gerekli fonksiyonların tanımlandığı python kütüphaneleri başlıca 'tensorflow', 'keras', 'numpy', 'pandas', 'matplotlib', 'seaborn' ve 'scikit-learn' olarak verilebilir. Keras, python programlama dilinde

yazılmış açık kaynaklı bir makine öğrenimi kitaplığıdır. Sinir ağları oluşturmak ve eğitmek için kullanılır. TensorFlow, Google tarafından geliştirilen açık kaynaklı bir derin öğrenme kitaplığıdır. Keras ile birlikte kullanılır. NumPy ve Pandas, derin öğrenme modellerine girdi olacak verileri hazırlamak veya uygun formata getirmek için kullanılan iki temel Python kütüphanesidir. NumPy, matematiksel işlemler ve çok boyutlu diziler için kullanılır. Bir LSTM modelinin girdisi numpy veri formatında olmak zorundadır. Pandas, veri çerçeveleri (dataframe) ve serilerle çalışmak için kullanışlıdır. Scikit-learn, modeli eğitmek ve değerlendirmek için kullanılan bir makine öğrenimi ve derin öğrenme kütüphanesidir. Özellikle veri bölme, çapraz doğrulama ve performans metrikleri gibi görevler için kullanışlıdır. Matplotlib ve Seaborn, model sonuçlarını görselleştirmek ve eğitim sürecini izlemek için kullanılır.

Uygulaması yapılan LSTM modeline ait parametreler **Tablo 4.2**'de verilmiştir. Parametre seçimleri yapılırken deneme-yanılma ve literatürde sık kullanılan parametreler dikkate alınarak yapılmıştır.

**Tablo 4.2** Uygulaması yapılan LSTM modelinin özellikleri

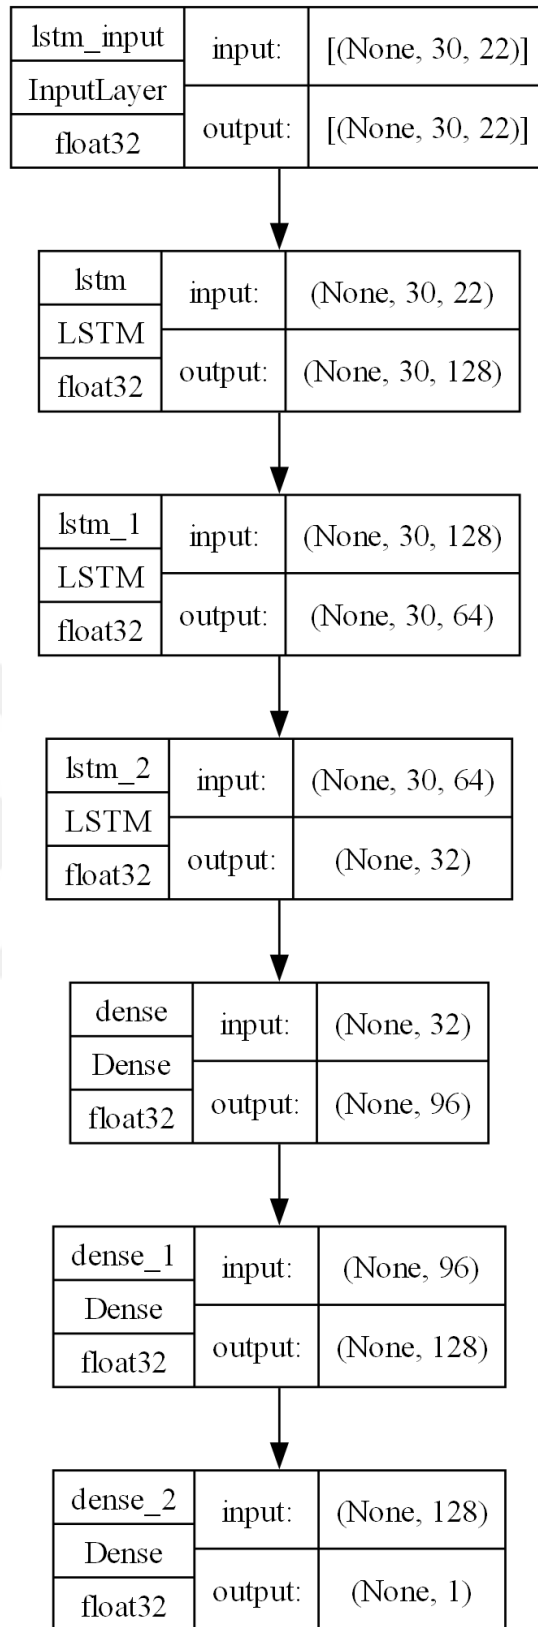
Hiper Parametre	Değer
LSTM katman sayısı	3
LSTM yoğun katman sayısı	3
Öğrenme hızı	0.01 & 0.001
Aktivasyon fonksiyonu	tanh
Öğrenme sayısı	10
Seri (Batch) boyutu	64
Optimize edici	Adam

LSTM katmanları ve model ile ilgili detaylar **Şekil 4.6**'da verilmiştir. Görseldeki modelin giriş katmanı, "input\_shape=(window\_length, 22)" parametresini kullanır. Bu parametre, modele verilen verilerin boyutunu belirtir. "window\_length" parametresi, modelin her bir tahmin için kullandığı zaman adımlarını belirtir. Her bir zaman adımı, 22 özellik içerir. Burada, C-MAPSS eğitim veri setinde bulunan 21 farklı sensor ve ilişkili hesaplanmış RUL değerleri modele girdi olarak verilmiştir. Modelin çıktı boyutu 1'dir. Bu, modelin tahmin olarak tek bir değer ürettiği anlamına gelir. Diyagramdaki oklar model boyunca veri akışını temsil etmektedir. Giriş verileri modele giriş katmanından girer ve modelden çıkış katmanından çıkar. LSTM katmanları verileri işler ve veriler model boyunca akarken hücre durumlarını günceller.

Görseldeki modelde (**Şekil 4.6**), LSTM katmanları, 128, 64 ve 32 hücreye sahiptir. Bu, modelin orta karmaşıklıkta olduğunu gösterir. Daha karmaşık bir model oluşturmak için, her bir LSTM katmanında daha fazla hücre kullanılabilir. Ancak, model eğitim süresini uzatacaktır.

Modelin adım adım çalışması şu şekildedir:

- Giriş katmanı, modele verilen verileri 22 boyutlu bir dizi vektöre dönüştürür. Bu vektörler, Python'da NumPy array veri tipi olarak adlandırılır.
- Birinci LSTM katmanı, bu vektörleri işler ve hücre durumunu günceller. Birinci LSTM katmanı, 128 hücreye sahiptir.
- İkinci LSTM katmanı, birinci LSTM katmanından gelen hücre durumunu işler ve hücre durumunu günceller. İkinci LSTM katmanı, 64 hücreye sahiptir.
- Üçüncü LSTM katmanı, ikinci LSTM katmanından gelen hücre durumunu işler ve hücre durumunu günceller. Üçüncü LSTM katmanı, 32 hücreye sahiptir.
- Çıkış katmanı, üçüncü LSTM katmanından gelen hücre durumunu tek bir değere dönüştürür. Çıkış katmanı, 1 hücreye sahiptir.



Şekil 4.6 Uygulanması yapılan LSTM modeli katmanları

#### 4.2.2 Model Performans Değerlendirme Metrikleri

LSTM modellerinin performansını değerlendirmek için kök ortalama kare hata (RMSE) performans ölçütü ve Pearson korelasyon katsayısı (PCC) kullanılmıştır. RMSE ve PCC'nin matematiksel ifadeleri sırasıyla denklem (4.3) ve denklem (4.4)'de verilmiştir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.3)$$

$$PCC = \frac{\sum_{i=1}^N (y_i - \mu_{y_i})(\hat{y}_i - \mu_{\hat{y}_i})}{\sqrt{\sum_{i=1}^N (y_i - \mu_{y_i})^2} \sqrt{\sum_{i=1}^N (\hat{y}_i - \mu_{\hat{y}_i})^2}} \quad (4.4)$$

Denklem (4.3) ve denklem (4.4)'de  $y_i$ ,  $i$  gözlemi için gerçek RUL değerini;  $\hat{y}_i$ , tahmin edilen RUL değerini ve  $N$  gözlem sayısını temsil etmektedir.

RMSE genellikle gerçek ve tahmin edilen değerler arasındaki hatayı hesaplamak ve modelin tahmin performansını değerlendirmek için kullanılır. Düşük RMSE değerleri modelin daha iyi tahminlerde bulunduğunu ve daha az hata yaptığını gösterir. Daha yüksek değerler modelin performansının düşük olduğunu gösterir.

PCC değeri -1 ile 1 arasındadır ve gerçek değerler ile tahmin edilen değerler arasındaki benzerliği temsil eder. Yorumlanması aşağıdaki gibidir;

- PCC değeri -1 'e yakınsa: Güçlü bir negatif ilişki vardır. Gerçek ve tahmin edilen değerler arasında ters bir ilişki olduğunu gösterir. Değişkenlerden biri artarken diğeri azalır.
- PCC 1'e yakınsa: Güçlü bir pozitif ilişki vardır. Gerçek ve tahmin edilen değerler arasında doğrusal bir ilişki olduğunu gösterir. Değişkenlerden biri arttığında diğeri de artar.
- PCC *NaN* (geçersiz sayı) çıktısı verdiğinde: Bu, PCC'nin hesaplanması için yeterli tahmin edilen değer olmadığını veya tahmin edilen değerlerin aynı değere sahip olduğunu gösterir.

### 4.3 Normalizasyon Teknikleri

Normalizasyon, veri setindeki sayısal değerleri belirli bir düzene sokma işlemidir. Bu düzen, genellikle belirli bir aralık veya standart bir dağılım olabilir. Normalizasyonun temel amacı, farklı ölçeklerdeki değişkenleri aynı ölçeğe getirerek, bu değişkenler arasında doğru karşılaştırmalar yapılmasını sağlamaktır. Normalizasyon, veri analizi ve modelleme işlemlerinde önemli rol oynayan bir tekniktir. Verilerin anlaşılabilirliğini ve kullanılabilirliğini artırmaya yardımcı olur. Örneğin, bir havayolu, uçuşların yakıt tüketimini azaltmak için, uçuş planlarını optimize etmek için bir makine öğrenme algoritması kullanıyor olabilir. Bu algoritma, uçağın ağırlığı, yakıt türü, vb. gibi değişkenleri kullanır. Bu değişkenler farklı ölçeklerde olabilir. Normalizasyon, bu değişkenleri aynı ölçeğe getirerek, algoritmanın daha doğru ve güvenilir tahminler yapmasına yardımcı olabilir.

RUL tahmini için kullanılan sensör ölçüm verileri genellikle farklı birimlere veya ölçeklere sahiptir. Örneğin, bir sensör sıcaklık değerlerini temsil ederken başka bir sensör titreşim değerlerini temsil edebilir. Bu farklı ölçekler, derin öğrenme modelinin kalıpları ve ilişkileri doğru bir şekilde öğrenmesini zorlaştırabilir. Normalizasyon, verileri belirli bir aralığa veya standart dağılıma dönüştürerek ölçek farklılıklarını ortadan kaldırır ve modellerin daha tutarlı ve karşılaştırılabilir sonuçlar üretmesini sağlar [39]. RUL tahmini için en yaygın olarak kullanılan teknikler minimum-maksimum [11], [41], [60] ve z-skoru [43], [70] normalizasyon teknikleridir.


#### 4.3.1 Minimum-Maksimum Normalizasyon Uygulaması

Minimum-maksimum normalizasyon, verileri belirli bir aralığa dönüştürmek için kullanılan bir yöntemdir. Bu yöntem, veri değerlerini orijinal aralıklarından bağımsız olarak 0 ile 1 arasında bir değer aralığına sıkıştırır. Matematiksel formülü denklem (4.5)'de gösterilmiştir [39];

$$y_t = \frac{x_t - \min(x_t)}{\max(x_t) - \min(x_t)} \quad (4.5)$$

Denklem (4.5)'de,  $x_t$  sensör verileridir ve  $y_t$ ,  $t$  zaman adımıdaki normalize edilmiş sensör verileridir.  $\max(x_t)$  ve  $\min(x_t)$ ,  $t$  zaman adımıdaki minimum ve maksimum sensör değerlerini temsil eder.

C-MAPSS eğitim ve test veri setlerindeki 21 sensör için başarılı bir şekilde minimum-maksimum normalizasyon tekniği uygulanmıştır. Bu sensörler için her bir zaman adımıda ölçülen değerlerini  $x_{t1}, x_{t2}, \dots, x_{t20}, x_{t21}$  olarak ifade edebiliriz. Bu sensörlerin normalize edilmiş değerlerini ise  $y_{t1}, y_{t2}, \dots, y_{t20}, y_{t21}$  ifade edebiliriz. Örneğin, **Şekil 4.7 a)**'da 1. Motor, unitID '1', için ilk 175 zaman adımı boyunca 15. sensöre ait ölçüm verileri,  $x_{t15}$ , görülmektedir. **Şekil 4.7 b)**'de ise normalize edilmiş veriler,  $y_{t15}$ , verilmiştir. Grafikler incelendiğinde, normalizasyon işleminin orijinal verinin temel örüntülerini ve trendini değiştirmedeği, orijinal veriyi bozmadığı gözlemlenmektedir.




**Şekil 4.7 a)** Eğitim veri setinde bulunan sensor\_15'e ait orijinal veriler **b)** normalize edilmiş veriler

### 4.3.2 Z-skoru Normalizasyonu

Z-skoru normalizasyonu,  $t$  zaman adımıdaki sensör verilerinin ortalamasının çıkarılmasını ve bu farkın standart sapmaya bölünmesini içerir. Bu yöntem, aşağıdaki (4.6) formülü kullanarak her zaman adımı için sensör verilerini normalleştirir.

$$y_t = \frac{(x_t - \mu)}{SD} \quad (4.6)$$

Denklem (4.6)'da  $y_t$ ,  $t$  zaman adımıdaki normalize edilmiş sensör verileri ve  $x_t$ ,  $t$  zaman adımıdaki ham sensör verileridir.  $\mu$ , tüm zaman adımları boyunca sensör verilerinin ortalaması ve  $SD$ , bu değerlerin standart sapmasıdır. C-MAPSS eğitim ve test veri setlerindeki 21 sensör için başarılı bir şekilde z-skoru normalizasyonu tekniği uygulanmıştır. 21 sensör için her bir zaman adımı ölçülen değerlerini  $x_{t1}, x_{t2}, \dots, x_{t20}, x_{t21}$  olarak ifade edebiliriz. Bu sensörlerin normalize edilmiş değerlerini ise  $y_{t1}, y_{t2}, \dots, y_{t20}, y_{t21}$  ifade edebiliriz. Örneğin, **Şekil 4.8 a)**'da 1. motor, unitID '1', için ilk 175 zaman adımı boyunca 15. Sensöre ait ölçüm verileri,  $x_{t15}$ , görülmektedir. **b)**'de ise  $y_{t15}$ , gösterilmiştir. Grafikler incelendiğinde, normalizasyon işleminin orijinal verinin trendini değiştirmedeği, orijinal veriyi bozmadığı gözlemlenmektedir.



a)

b)

**Şekil 4.8 a)** Eğitim veri setinde bulunan sensor\_15'e ait orijinal veriler **b)** normalize edilmiş veriler

## 4.4 Filtreleme Teknikleri

Filtreleme, sinyal işleme ve veri analizi alanlarında kullanılan bir terimdir ve genellikle bir sinyalden gürültüyü çıkarmayı veya sinyali düzeltmeyi ifade eder. Bu, özellikle ölçümlerden veya sensör verilerinden elde edilen sinyallerdeki gürültüyü azaltmak veya istenmeyen bileşenleri filtrelemek için kullanılır.

RUL tahmini, sensör verilerine dayanır ve bu veriler genellikle çeşitli gürültü kaynaklarından etkilenebilir. Filtreleme teknikleri, bu sensör verilerinden gelen gürültüyü temizlemeye ve tahmin modelinin daha doğru ve güvenilir olmasına yardımcı olur.

### 4.4.1 SG Filtre Tekniği Uygulaması

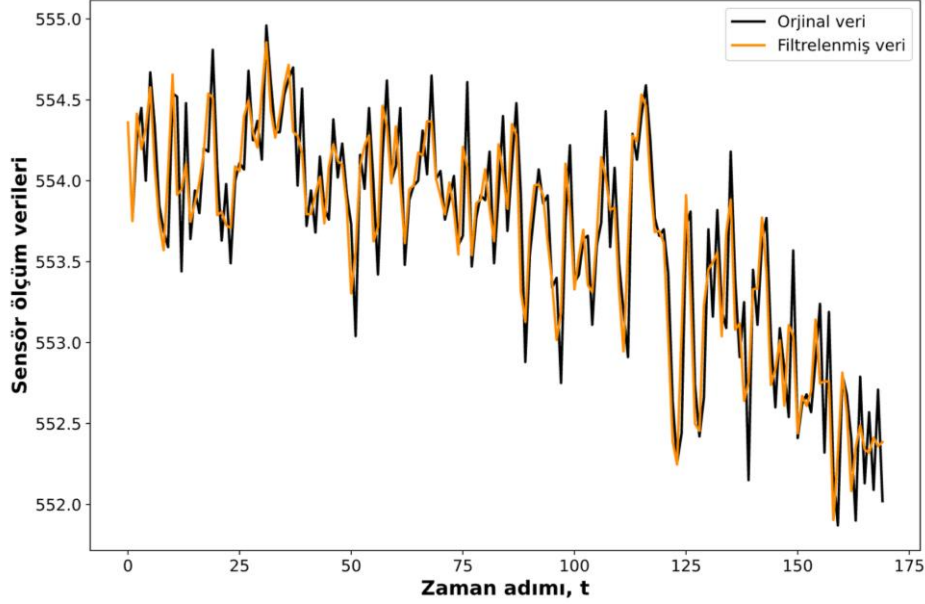
SG filtreleme, zaman serisi verilerindeki yumuşatma ve gürültü azaltma işlemleri için kullanılan bir tekniktir. SG filtresi, çok terimli yaklaşımı kullanan bir gürültü azaltma filtresidir. Bu filtre, bir penceredeki veri noktalarının ağırlıklı ortalamasını alarak çalışır. SG filtresinde kullanılan çok terimli fonksiyonun matematiksel formülü (4.7)'de verilmiştir.

$$y_t = c_0 + c_1x_t + c_2x_t^2 + \dots + c_nx_t^n \quad (4.7)$$

Çok terimlinin katsayıları,  $c_0, c_1, c_2, c_3, \dots, c_n$ , SG filtresi içinde karesel hataların toplamı en aza indirilerek hesaplanır [71].

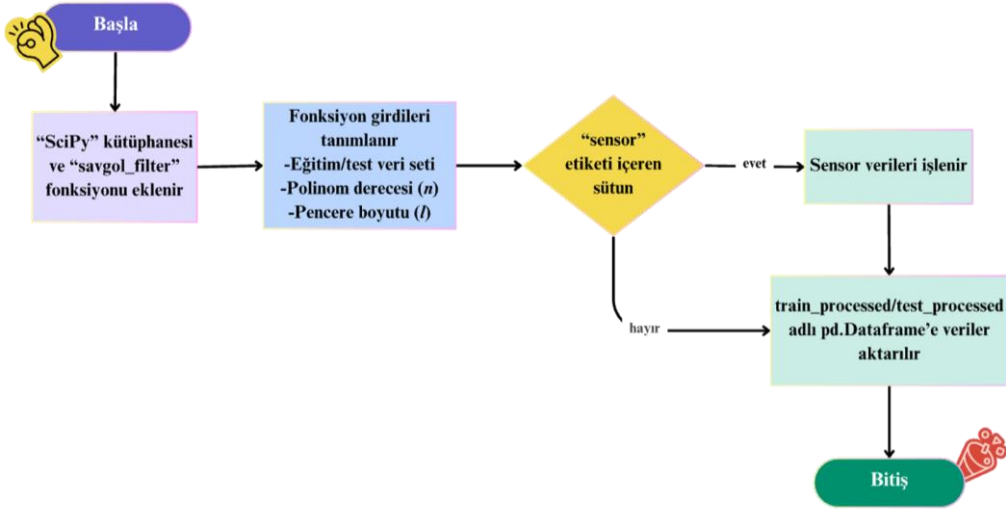
SG filtresini kullanmadan önce, başlangıçta pencere boyutu ve çok terimli derecesi seçilmelidir. Pencere boyutu, filtre tarafından dikkate alınacak olan veri noktalarının sayısını belirler. Çok terimli derecesi ise, filtrenin temel yapıyı ne kadar iyi yakalayacağını belirler. Bu filtreleme yönteminde kullanılan parametreler çok terimli derecesi,  $n$  ve pencere boyutu,  $l$ 'dir. Bu parametre seçimlerinin temel mantığı, gürültü azaltma ile sinyal değişikliklerine tepki verme arasında bir denge kurma ihtiyacındandır. Düşük çok terimli derecesi ve geniş bir pencere boyutu, özellikle daha yumuşak sinyallerin işlenmesi için uygundur. Diğer yandan, hızlı değişen sinyallerin daha iyi ele alınabilmesi için yüksek çok terimli derecesi ve daha küçük bir pencere boyutu gerekebilir. Parametrelerin optimize edilmesi süreci,

filtrelenmiş sinyalin görsel analizini de içerir. **Şekil 4.9**'da 1. motorun ilk 175 zaman adımı süresince, örnek olarak 7 numaralı sensör için uygulama sonucu verilmiştir.



**Şekil 4.9** sensor\_7 için SG filtresi ile gürültü azaltma


Bu filtreleme işlemi Python'da, "scipy.signal" kütüphanesinden "savgol\_filter" fonksiyonu kullanılarak yapılmıştır. Bu fonksiyonda, tanımlanması gereken girdiler için, 4 çok terimli derecesi ve 3 pencere boyutu tercih edilmiştir. Filtre, çeşitli karşılaştırmalı senaryolarda hem eğitim hem de test veri setlerinde bulunan tüm sensörlere uygulanmıştır. 21 farklı sensörün her biri için  $t$  zaman adımında ölçülen değerler  $x_{t1}, x_{t2}, \dots, x_{t20}, x_{t21}$  olarak gösterilebilir. Buna uygun olarak, bu sensörler için filtrelenmiş değerleri  $y_{t1}, y_{t2}, \dots, y_{t20}, y_{t21}$  olarak ifade edebiliriz.  $y_{t\{1-21\}}$  değerleri daha sonra ilgili senaryolarda normalize edilerek LSTM modeline girdi olarak sağlanmıştır. SG filtre uygulamasını gösteren akış diyagramı **Şekil 4.10**'da verilmiştir.



Şekil 4.10 SG filtre uygulaması akış diyagramı

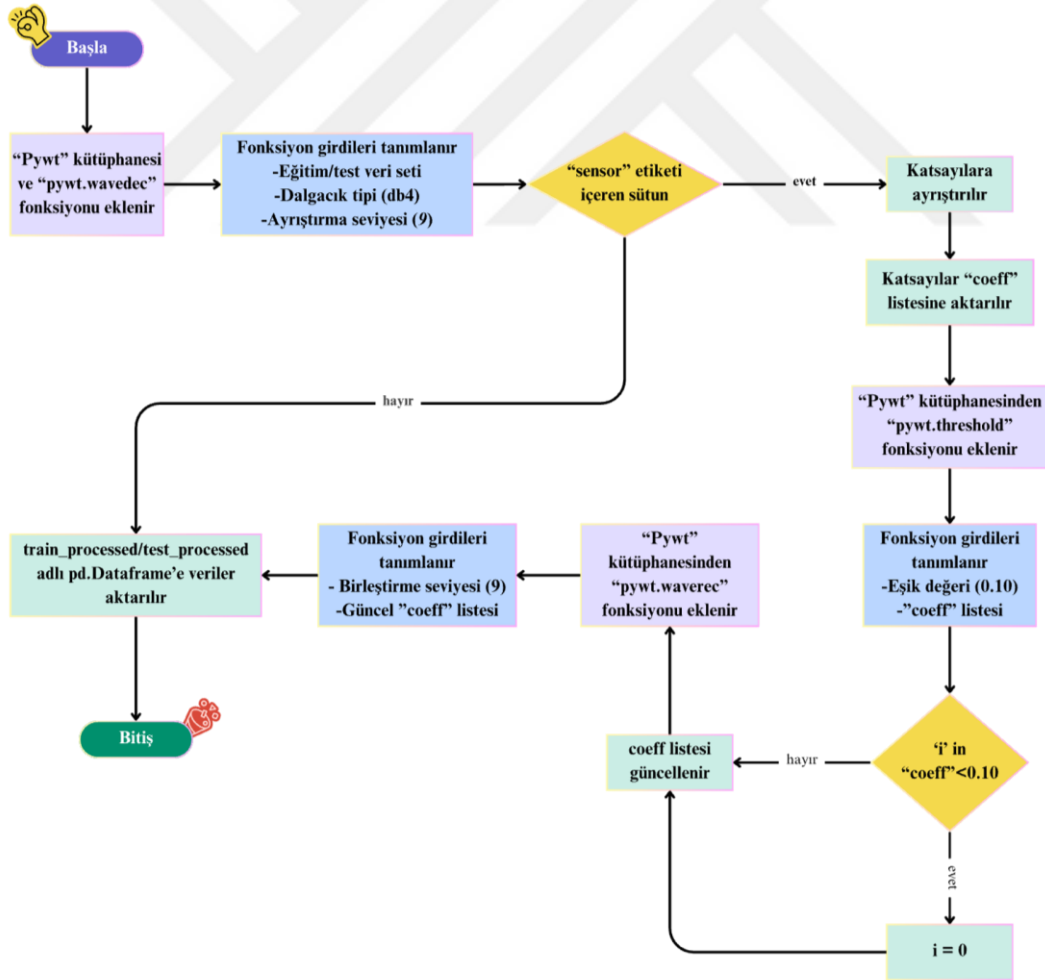
#### 4.4.2 Dalgacık Dönüşümü ile Gürültü Azaltma

“Daubechies” tipi dalgacık fonksiyonu, zaman ve frekans alanlarında lokalize olan küçük dalga benzeri salınımı ifade eder (ör., Şekil 4.11). Düşük frekanslı verilere odaklanan db1’den, yüksek frekanslı verilere odaklanan db20’ye kadar tanımlanmış 20 tip dalgacık vardır. Örneğin, “4” sayısı, “db4” dalgacığının dört katsayıya sahip olduğunu ve bu katsayıları dalgacık dönüşümünü gerçekleştirmek için kullanıldığını belirtir. Her bir dalgacık için tanımlanmış katsayılar vardır [72].



Şekil 4.11 db4 dalgacık fonksiyonu [72]

Phyton'da “pywt (PyWavelets)” adlı kütüphane kullanılarak, gürültü azaltma işlemi kolaylıkla yapılabilir. Pywt, bir dalgacık dönüşümü kütüphanesidir. Pywt, dalgacık dönüşümü işlemlerini gerçekleştirmek ve sinyalleri işlemek için bir dizi fonksiyon ve araç sunar. Görüntü işleme, sinyal işleme, veri sıkıştırma ve gürültü azaltma gibi uygulamalarda kullanılır. Dalgacık dönüşümü ile gürültü azaltma uygulaması **Şekil 4.12**'de gösterildiği gibi uygulanmıştır. **Şekil 4.12**'de gösterilen akış, dalgacık dönüşümü ve eşikleme işlemlerini içerir. Bu teknikte, gürültülü sinyal önce kullanılan dalgacık tipi (db4) ile ayrı katsayılara dönüştürülür. Daha sonra, bu katsayıların her biri, belirlenen bir eşik değeri, 0,10 kullanılarak eşiklenir. Eşik değeri, gürültü seviyesini belirlemek için kullanılır. Eşikleme işlemi, gürültü katsayılarını sıfıra eşitleyerek gürültüyü azaltır. Son olarak, eşiklenmiş katsayılar yeniden birleştirilerek sinyal tekrar oluşturulur.




**Şekil 4.12** Dalgacık dönüşümü ile gürültü azaltma uygulaması

Eşik deęerinin 0,1 olarak seçilmesi, aşırı yüksek gürültü seviyeleri olmayan veriler için uygun olan yumuşak bir gürültü azaltma işlemi anlamına gelir. Eşiklemedeki bu temkinli yaklaşım, sensör verilerinin temel yapısının bozulmasını önlemeye yardımcı olur. Aynı zamanda, 9'luk bir ayrıştırma seviyesi kullanma kararı, sinyalin ayrıntılı bir analizine işaret etmektedir. Dalgacık ayrıştırması, sinyali farklı frekans bantlarına böler ve yüksek ayrıştırma seviyesiyle, verilerin önemli bilgileri yüksek frekanslı bileşenlerinde taşıdığı düşüncesinden ilham alır. Orta düzeyde bir eşik ve yüksek bir ayrıştırma seviyesinin kombinasyonu, orijinal verilerin detaylarını korurken etkili bir şekilde gürültüyü azaltan dengeli bir yaklaşım sunar.

Dalgacık tabanlı gürültü azaltma sürecinde, ayrıştırma seviyesi ve eşik değeri iteratif olarak ayarlanarak, gürültüyü azaltma ve sinyali koruma arasında bir denge sağlanmaktadır. Yüksek bir ayrıştırma seviyesi ve düşük bir eşik değeri seçmek, potansiyel olarak orijinal sinyalin daha büyük bir kısmını koruma avantajına sahipken, aynı zamanda daha fazla gürültü içinde tutma riskini artırabilir. Bu seçim, daha detaylı ancak daha gürültülü bir sinyal elde etme potansiyelini beraberinde getirir. Öte yandan, düşük bir ayrıştırma seviyesi ve yüksek bir eşik değeri seçmek, gürültüyü etkili bir şekilde ortadan kaldırabilir, ancak sinyalin daha fazla bozulmasına yol açabilir [73], [74].

Filtre, çeşitli karşılaştırmalı senaryolarda hem eğitim hem de test veri setlerinde bulunan tüm sensörlere uygulanmıştır. 21 farklı sensörün her biri için  $t$  zaman adımında ölçülen değerler  $x_{t1}, x_{t2}, \dots, x_{t20}, x_{t21}$  olarak gösterilebilir. Buna uygun olarak, bu sensörler için filtrelenmiş değerleri  $y_{t1}, y_{t2}, \dots, y_{t20}, y_{t21}$  olarak ifade edebiliriz.  $y_{t\{1-21\}}$  değerleri daha sonra ilgili senaryolarda normalize edilerek LSTM modeline girdi olarak sağlanmıştır.



**Şekil 4.13** sensor\_7 için dalgacık dönüşümü ile gürültü azaltma

Eğitim veri kümesindeki bir sensör için filtreleme sonuçlarını gösteren **Şekil 4.13**'da motor 1'in ilk 175 zaman adımı süresince çalışırken ölçüm yapan sensör 7'nin değerleri ve buna karşılık gelen filtrenmiş değerler gösterilmektedir.

#### 4.4.3 EMA ile Gürültü Azaltma

EMA filtreleme, zaman serisi verilerindeki gürültüyü yumuşatmak ve azaltmak için kullanılan bir diğer yöntemdir. Geçmiş veri noktalarına üstel olarak azalan ağırlıklar atayarak çalışır; daha yeni veri noktaları daha yüksek ağırlıklar ve daha eski veri noktaları daha düşük ağırlıklar alır. Bu yaklaşım, filtrenin sinyaldeki son değişiklikleri etkili bir şekilde yakalamasına ve aynı zamanda eski verilerden gelen bilgileri de dahil etmesine olanak tanır.

EMA filtresi tipik olarak aşağıdaki formül kullanılarak uygulanır:

$$y_t = \alpha * x_t + (1 - \alpha) * y_{t-1} \quad (4.8)$$

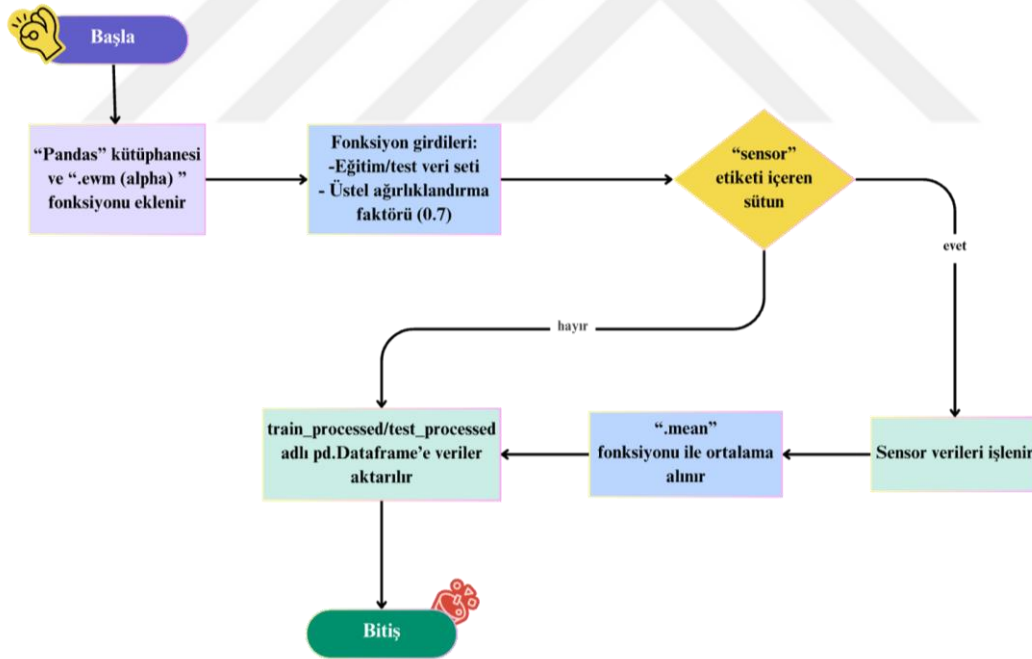
Burada:

- $y_t$ ,  $t$  zaman adımıdaki filtrenmiş değerdir,
- $x_t$ ,  $t$  zaman adımıdaki ham sensör değeridir,


- $y_{t-1}$  bir önceki zaman adımındaki,  $t - 1$ , filtrelenmiş değerdir,
- $\alpha$  üstel ağırlıklandırma faktörüdür ve 0 ile 1 arasında değerler alabilir.

Üstel ağırlıklandırma faktörü  $\alpha$ , son ve geçmiş verilerin göreceli önemini belirler. Daha yüksek bir  $\alpha$  değeri, sinyaldeki gerçek zamanlı değişiklikleri etkili bir şekilde yakalayarak daha yeni verilere öncelik verir. Diğer yandan, daha düşük bir  $\alpha$  değeri daha eski verileri vurgulayarak daha uzun vadeli eğilimlerin korunmasını sağlar [75]. Üstel ağırlıklandırma faktörü,  $\alpha = 0,7$ , iteratif olarak belirlenmiştir ve filtre bu değerle tüm sensor verileri üzerinde uygulanmıştır.

Phyton'da, Pandas kütüphanesi kullanılarak EMA filtresi kolaylıkla uygulanabilir. Pandas, Python programlama dilinde veri analizi ve manipülasyonu için kullanılan açık kaynaklı bir kütüphanedir. Temel olarak, veri çerçeveleri (dataframes) ve seriler (series) adlı iki ana veri tipi ile çalışır. Phyton'da uygulaması yapılan EMA ile gürültü azaltma işlemine ait akış diyagramı Şekil 4.14'de verilmiştir.



Şekil 4.14 EMA ile gürültü azaltma uygulaması



**Şekil 4.15** sensor\_7 için EMA filtresi ile gürültü azaltma

Filtre, çeşitli karşılaştırmalı senaryolarda hem eğitim hem de test veri setlerinde bulunan tüm sensörlere uygulanmıştır. 21 farklı sensörün her biri için  $t$  zaman adımında ölçülen değerler  $x_{t1}, x_{t2}, \dots, x_{t20}, x_{t21}$  olarak gösterilebilir. Buna uygun olarak, bu sensörler için filtrelenmiş değerleri  $y_{t1}, y_{t2}, \dots, y_{t20}, y_{t21}$  olarak ifade edebiliriz.  $y_{t\{1-21\}}$  değerleri daha sonra ilgili senaryolarda normalize edilerek LSTM modeline girdi olarak sağlanmıştır.

Eğitim veri kümesindeki 7 numaralı sensör için filtreleme sonuçlarını gösteren **Şekil 4.15**'de 1 numaralı motorun ilk 175 zaman adımı süresince çalışırken ölçüm yapan 7 numaralı sensöre ait ölçüm değerleri ve buna karşılık gelen filtrelenmiş değerler gösterilmektedir.

## 5.1 Analizler ve Bulgular

Bu çalışmada, veri ön işleme tekniklerinin farklı kombinasyonlarını içeren farklı senaryolar belirlenmiş ve aynı parametrelere sahip LSTM modeline uygulanmıştır. Deneylein amacı, bir LSTM modeli kullanarak RUL tahminlerinin doğruluğunu artırmada farklı veri ön işleme kombinasyonlarının etkinliğini dikkatlice araştırmak ve değerlendirmek ve sonuçta en doğru RUL tahminlerine yol açan en uygun ön işleme stratejilerini belirlemektir. Belirlenen senaryoların etiketleri **Tablo 5.1**'de, kıyaslama senaryoları için belirlenmiş kombinasyonlar ve etiketleri ise **Tablo 5.2**'te listelenmiştir.

**Tablo 5.1** Uygulanan senaryolar ve etiketleri

Senaryo Etiketleri	Uygulanan Teknikler
SN1	LSTM
SN2	SG filtre + LSTM
SN3	Dalgacık dönüşümü + LSTM
SN4	EMA + LSTM
SN5	Minimum-maksimum normalizasyon + LSTM
SN6	SG filtre + Minimum-maksimum normalizasyon + LSTM
SN7	Dalgacık dönüşümü + Minimum-maksimum normalizasyon + LSTM
SN8	EMA + Minimum-maksimum normalizasyon + LSTM

**Tablo 5.1** Uygulanan senaryolar ve etiketleri (devamı)

SN9	Z-skoru normalizasyonu + LSTM
SN10	SG filtresi+ Z-skoru normalizasyonu + LSTM
SN11	Dalgacık dönüşümü + Z-skoru normalizasyonu + LSTM
SN12	EMA + Z-skoru normalizasyonu + LSTM


**Tablo 5.2** Kıyaslama senaryoları ve etiketleri

Kıyaslama senaryo etiketleri	Kıyaslaması yapılan senaryolar
comparativeSN_1	SN2, SN3, SN4
comparativeSN_2	SN6, SN7, SN8
comparativeSN_3	SN10, SN11, SN12
comparativeSN_4	SN1, SN5, SN9
comparativeSN_5	SN2, SN6, SN10
comparativeSN_6	SN3, SN7, SN11
comparativeSN_7	SN4, SN8, SN12

Kıyaslama senaryolarını tanımlarken, ham sensör verilerine uygulanan en etkili filtreleme tekniği comparativeSN\_1’de, minimum-maksimum normalizasyon yöntemi kullanıldığında en iyi filtreleme tekniği comparativeSN\_2’de ve z-skoru normalizasyon tekniği ile uygulandığında en iyi filtreleme tekniği comparativeSN\_3’de araştırıldı. Ayrıca, normalizasyon tekniğinin LSTM modelinin performansı üzerindeki etkisini değerlendirmek adına karşılaştırmalı senaryolar olan comparativeSN\_4, comparativeSN\_5, comparativeSN\_6 ve

comparativeSN\_7 üzerinde kıyaslama gerçekleştirildi. Tanımlanan kombinasyonlara sahip ilgili kıyaslama senaryolarında; SG, dalgacık dönüşümü ve EMA teknikleri ile filtrelenen sensör verileri veya ham sensör verileri; normalizasyon işlemi yapılmadan, minimum-maksimum veya z-skoru yöntemi ile normalize edilerek LSTM modeline girdi olarak sağlanmıştır. İşlenmiş veriler üzerinde eğitilen LSTM modellerinin performansı RMSE ve PCC metrikleri kullanılarak kıyaslanmıştır.

comperativeSN\_1 senaryosunda, ham sensor verileri sadece filtrelenmiş ve LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.3**'te ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.1**'de verilmiştir. RUL tahmin grafiğinde, 'unitID' değerleri test veri setindeki 100 adet motorun numaralandırmasını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri sergilenmektedir.




**Şekil 5.1** comparativeSN\_1'de en iyi skora sahip senaryo (SN2) için RUL tahmini

**Tablo 5.3** comparativeSN\_1 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN2	42,03	NaN
SN3	42,10	NaN
SN4	42,04	NaN

comperativeSN\_2 senaryosunda, SG, dalgacık dönüşümü veya EMA teknikleri ile filtrelenen sensor verileri minimum-maksimum tekniği ile normalize edilmiş ve LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.4**'te ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.2**'de verilmiştir.

RUL tahmin grafiğinde, "unitID" değerleri test veri setindeki 100 adet motorun numaralandırmasını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri sergilenmektedir.




**Şekil 5.2** comparativeSN\_2'de en iyi skora sahip senaryo (SN8) için RUL tahmini

**Tablo 5.4** comparativeSN\_2 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN6	15,45	0,9201
SN7	22,70	0,8503
<b>SN8</b>	<b>15,32</b>	<b>0,9301</b>

comperativeSN\_3 senaryosunda, filtrelenen sensor verileri z-skoru tekniği ile normalize edilmiş ve LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.5**'te ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.3**'te verilmiştir. RUL tahmin grafiğinde, “unitID” değerleri test veri setindeki 100 adet motor numaralarını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri sergilenmektedir.




**Şekil 5.3** comparativeSN\_3'de en iyi skora sahip senaryo (SN10) için RUL tahmini

**Tablo 5.5** comparativeSN\_3 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN10	13,57	0,9466
SN11	24,18	0,8374
SN12	14,28	0,9393

comperativeSN\_4 senaryosunda, herhangi bir filtreleme tekniği uygulanmadan, sensor verileri z-skoru tekniği ile normalize edilmiş ve LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.6**'da ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.4**'te verilmiştir. RUL tahmin grafiğinde, "unitID" değerleri test veri setindeki 100 adet motorun numaralandırmasını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri sergilenmektedir.




**Şekil 5.4** comparativeSN\_4'de en iyi skora sahip senaryo (SN9) için RUL tahmini

**Tablo 5.6** comparativeSN\_4 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN1	41,78	NaN
SN5	15,80	0,9314
<b>SN9</b>	<b>14,81</b>	<b>0,9223</b>

comparativeSN\_5 senaryosunda, SG tekniği ile filtrelenmiş sensör verileri; herhangi bir normalizasyon işlemi uygulanmamış, z-skoru tekniği veya minimum-maksimum ile normalize edilmiş şekilde LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.7**'de ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.5**'te verilmiştir. RUL tahmin grafiğinde, "unitID" değerleri test veri setindeki 100 adet motor numaralarını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri gösterilmektedir.




**Şekil 5.5** comparativeSN\_5'de en iyi skora sahip senaryo (SN10) için RUL tahmini

**Tablo 5.7** comparativeSN\_5 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN2	42,03	NaN
SN6	15,45	0,9201
<b>SN10</b>	<b>13,57</b>	<b>0,9466</b>

comparativeSN\_6 senaryosunda, dalgacık dönüşümü tekniği ile filtrelenmiş sensör verileri; herhangi bir normalizasyon işlemi uygulanmamış, z-skoru veya minimum-maksimum ile normalize edilmiş şekilde LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.8**'de ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.6**'da verilmiştir. RUL tahmin grafiğinde, "unitID" değerleri test veri setindeki 100 adet motorun numaralarını göstermektedir. Her bir motorun son zaman adımıdaki RUL tahmini ile doğrulama veri setinde bulunan gerçek RUL değerleri sergilenmektedir.




**Şekil 5.6** comparativeSN\_6'da en iyi skora sahip senaryo (SN7) için RUL tahmini

**Tablo 5.8** comparativeSN\_6 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN3	42,10	NaN
<b>SN7</b>	<b>22,70</b>	<b>0,8503</b>
SN11	24,18	0,8374

comparativeSN\_7 senaryosunda, EMA tekniği ile filtrelenmiş sensör verileri; herhangi bir normalizasyon işlemi uygulanmamış, z-skoru veya minimum-maksimum ile normalize edilmiş şekilde LSTM modeline girdi olarak sağlanmıştır. LSTM model performans metrikleri kullanılarak elde edilen sonuçlar, **Tablo 5.9**'da ve performans metriklerinin sonuçlarına göre en yüksek skora sahip senaryo için tahmin edilen RUL değerleri ile doğrulama veri setinde yer alan gerçek RUL değerlerinin kıyaslandığı grafik, **Şekil 5.7**'de verilmiştir. Grafikte, “unitID” değerleri test veri setindeki 100 adet motor numaralarını göstermektedir.



**Şekil 5.7** comparativeSN\_7'da en iyi skora sahip senaryo (SN12) için RUL tahmini

**Tablo 5.9** comparativeSN\_7 sonuçları

Kıyaslanan senaryo etiketi	RMSE	PCC
SN4	42,04	NaN
SN8	15,32	0,9301
<b>SN12</b>	<b>14,28</b>	<b>0,9393</b>

## 5.2 Bulguların Değerlendirilmesi

Tüm kıyaslama senaryolarında (comparativeSN\_{1-7}) elde edilen bulgulara göre **Tablo 5.10**'da en iyi performans gösteren senaryolar ve sonuçları listelenmiştir. Tablo incelendiğinde (**Tablo 5.10**), SN8, SN9, SN10 ve SN12 oldukça yakın RMSE ve PCC değerler ile başarılı sonuçlara işaret etmektedir. Özellikle, SG tekniği ile birlikte z-skoru normalizasyon yöntemi kullanılarak eğitilen LSTM modeli, en düşük RMSE ve en yüksek PCC değerlerini sergileyerek en iyi performans gösteren senaryo olarak ortaya çıkmıştır. Bununla birlikte, dalgacık dönüşümü ve EMA filtrelemesinin uygulanmasından elde edilen sonuçlar da LSTM modelinin performansı üzerinde olumlu bir etki göstermiştir. Bu gözlem, LSTM modelini optimize etmenin, filtreleme tekniklerinde ince ayar yapmanın yanı sıra dalgacık dönüşümü veya EMA tekniklerini kullanmanın optimum performans sonuçlarına yol açabileceğini ve uygulanabilir yöntemler olduğunu kanıtladığını göstermektedir.

**Tablo 5.10** Kıyaslama senaryolarında, comparativeSN\_{1-7}, en iyi skora sahip senaryolar

Kıyaslanan senaryo etiketi	RMSE	PCC
SN7	22,70	0,8503
SN8	15,32	0,9301
SN9	14,81	0,9223
<b>SN10</b>	<b>13,57</b>	<b>0,9466</b>
SN12	14,28	0,9393

### 5.3 Tartışma

Bu çalışmada, havacılık endüstrisinde zaman serisi verileri kullanılarak RUL tahmini için veri tabanlı bir yaklaşım üzerinde durulmaktadır. Fizik tabanlı veya hibrit tabanlı sistemlerin daha etkili ve başarılı olma potansiyeline sahip olmasına rağmen, havacılık endüstrisinde artan maliyetler nedeniyle tercih edilmeme durumu göz önüne alındığında, veri tabanlı yaklaşım daha uygun bir çözüm olarak görülebilir. Veri tabanlı prognostik yaklaşımlar çeşitli uçak sistemleri için incelendiğinde, özellikle kullanılan derin öğrenme tekniklerinin tiplerinde belirgin bir benzerlik olduğu gözlemlenmiştir. Örneğin, uçak turbofan motorları için yapılan RUL tahminlerinde kullanılan derin öğrenme modellerinin, elektrik sistemine ait APU için de başarıyla kullanıldığı görülmektedir.

Hibrit tabanlı veya fizik tabanlı modeller sistem veya ekipman hakkında derin bilgi, zaman ve maliyet gerektirmektedir. Örneğin, F-35 savaş uçağı programına ait PHM sistem geliştiricileri, “Joint Strike Fighter Program Office”, tarafından yayımlanan bir konferans bildirisinde [10] gerçek dünyadaki, yani pratikteki prognostik aktivitelerindeki zorluklardan ve maliyetlerden bahsedilmiştir. RUL tahmini için prognostik modellerin geliştirilmesi ile ilgili olarak bir sistemin performansındaki bozulma eğilimi, genellikle en basit prognostik formunu oluşturduğu ve kesin bir tahmin sonucu sağlamasa da filo operatörleri için çok değerli bilgiler sağladığından bahsedilmiştir. Konferans bildirisinde bahsedilen örneğe göre, bir bileşenin

performansı, arızaya yaklaştıkça bozulmaya başlarsa, bu, operatörün bileşeni daha önce değiştirmesini sağlar. Bu pratik yaklaşımın, uçuş güvenliğini artırmaya ve bakım maliyetlerini düşürmeye yardımcı olduğu belirtilmiştir. Fizik tabanlı veya hibrit tabanlı prognostik yaklaşımlar için olmazsa olmaz olan FMEA analizi yani sistemin veya ekipmanların detaylı hata durumlarının ve mekanizmalarının incelenmesinin maliyet, zaman ve emek açısından uygulaması zor olan yaklaşımlar olduğu anlaşılmaktadır. Özellikle uçak sistemlerinin gelişmesi ve dijitalleşmesi ile daha kompleks hale geldiğinden hata mekanizmalarını anlamının mümkün olmadığı durumlar olduğu belirtilmiştir. Prognostik yaklaşımın kompleks hale gelmesi, model performansını iyileştirmeyi garanti etmeyebilir. Örneğin hibrit tabanlı prognostik yaklaşım üzerinde yapılan bir çalışmada [8], uçak motoru için yapılan detaylı gözlem ile elde edilen sağlık parametreleri, C-MAPSS veri setine entegre edilerek LSTM, CNN ve FNN modelleri üzerinde eğitilmiş ve model performansları hem birbirleri ile RMSE metriği üzerinden, hem de literatürde yapılan benzer çalışmalar ile kıyaslanmıştır. Aynı zamanda, veri tabanlı prognostik yaklaşım ile, fiziksel modelden gelen sağlık parametrelerini kullanmadan, sadece LSTM, CNN ve FNN modellerine ait sonuçlar ile de kıyaslama yapılmıştır. Veri ön işleme kısmında ise minimum-maksimum normalizasyon kullanıldığı görülmüştür. LSTM model performansı, hibrit tabanlı prognostik yönteminde RMSE değeri 16,9; veri tabanlı prognostik yöntemde ise 19,6 çıkmıştır. Sonuçlar göstermektedir ki, minimum-maksimum normalizasyon ile uygulamasını yaptığımız LSTM model performansı, model parametreleri farklı olsa da veri seti aynı olmasına rağmen bizim çalışmamızda (SN5) RMSE değeri 15,80 çıkarak, hibrit tabanlı bir yaklaşımın getirdiği kompleksliğin yüksek doğrulukla RUL tahmini demek olmadığını ispatlayabilir. Fizik ve hibrit tabanlı çalışmalar, literatürde haklı bir değerlendirmeye sahiptir; ancak günümüzde, özellikle havacılık alanında, uçak sistemlerine ait veri miktarının sürekli arttığı bir ortamda, veri tabanlı prognostik yaklaşım yani makine öğrenmesi veya derin öğrenme modelleri kullanılarak, veri ön işleme adımlarının dikkatli bir şekilde optimize edilmesi daha pratik, maliyet etkin ve yüksek doğrulukla RUL tahminleri sağlamak için etkili bir yaklaşım olabilir. Bu çerçevede, veri büyüklüğündeki artış göz önüne alındığında, endüstriyel uygulamalarda bu yaklaşımın kullanılması, daha hızlı ve etkili sonuçlar elde edilmesine katkı sağlayabilir.

Herhangi bir normalizasyon tekniđi uygulaması olmadan sadece filtreleme teknikleri ile LSTM modeli uygulandıđında RMSE deđerleri yaklaşık 40 ve üzeri çıkmıřtır ve PCC deđerleri tahmin edilen ve gerek deđerler arasında korelasyon olmadığı için NaN olarak çıkmıřtır. Burada, hangi veri ön iřleme tekniđi uygulanırsa uygulansın, zaman serisi verileri için mutlaka normalizasyon iřleminin yapılması gerektiđi ortaya çıkmıřtır. Son yıllarda yapılan alıřmalar incelendiđinde, rneđin 2023'te yapılan bir alıřmada, normalizasyon tekniđinin zaman serisi verileri için uygulama zorunluluđu olduđundan bahsedilmiřtir [23].

Herhangi bir filtreleme tekniđi uygulanmadan sadece normalizasyon teknikleri uygulandıđında en iyi performans gsteren senaryo z-skoru normalizasyon tekniđi ile LSTM modelinin uygulandıđı SN9 olmuřtur. SN9 için RMSE deđeri 14,81 olarak hesaplanmıřtır. C-MAPSS veri seti üzerinde yapılan bir alıřmada da z-skoru tekniđi LSTM ile birlikte kullanılmıř ve RMSE deđeri 14,72 olarak hesaplanmıřtır [70]. Elde ettiđimiz sonu ile kıyasladıđımızda sonuların arasındaki ufak farklılık, LSTM model parametre seimi ve RUL tahmini için faydalı olmayacađı dřünlen, eđitim veri seti için hesaplanan RUL deđerleri ile herhangi bir korelasyonun tespit edilemediđi bazı sensrlerin veri setinden ıkartılarak modelin eđitilmesinden kaynaklanıyor olabilir. Sadece minimum-maksimum normalizasyon ile LSTM uygulandıđında (SN5) ise RMSE metriđi 15,80 olmuřtur. Aynı veri seti üzerinde yapılan bir alıřmanın veri ön iřleme kısmında, zamanla hibir deđiřime uđramayan yani standart sapması 0'a yakın olan sensrler veri setinden ıkarılmıř, diđer kalan sensrler minimum-maksimum ile {0-1} deđerleri kullanılarak normalize edilmiř ve LSTM modelinde eđitilmiřtir, model performansını lmek için kullanılan RMSE sonucu ise 15,51 çıkmıřtır [75]. Bu alıřmada uygulanan LSTM modeli ile birebir aynı parametreler kullanılsa da sonuların ok yakın ıktıđını syleyebiliriz. Bir bařka alıřma için de yine aynı veri ön iřleme, aynı veri seti ve LSTM modeli performansı için de benzer RMSE deđerleri olarak 16,14 elde edildiđini gryoruz [20]. Z-skoru normalizasyon tekniđinin uygulandıđı senaryo (SN9) ile minimum-maksimum tekniđinin uygulandıđı senaryoya (SN5) kıyasla, SN9'daki sonuların daha iyi ıkmasının sebebi dřnldđnde, aykırı deđerlerin RUL tahmininde dođrudan neminin olmaması olabilir. RUL, bir ekipmanın arızalanmasına kadar kalan sreyi ifade eder. Aykırı deđerler, bir veri setinde belirli bir noktanın belirli bir durumu temsil

ettiğini gösteren verilerdir. Örneğin, bir ekipmanın çalışma durumu "çalışıyor" veya "arızalı" olabilir. Aykırı değerler, ekipmanın RUL değerini tahmin etmek için doğrudan kullanılmayabilir. Havacılıkta, diagnostik ve prognostik çalışmalar ayrı iki disiplindir ve çalışmaların sonuçları birlikte değerlendirilerek bakım öngörüsü kararı için destek verir. Diagnostik çalışmalar, bir ekipmanın arızalı olup olmadığını belirlemeye yönelik çalışmalardır ve veri setindeki aykırı değerlerin önemi bu disiplin için ön plandadır. Bu durumda, z-skoru normalizasyon tekniği yerine, aykırı değerlerin etkisini azaltmayan veya ortadan kaldırmayan başka bir normalizasyon tekniği kullanmak daha doğru olabilir. Örneğin, bu durumda, minimum-maksimum normalizasyon tekniği kullanılabilir. Prognostik için ise, z-skoru normalizasyon tekniği kullanılarak veriler standart normal dağılıma dönüştürüldüğünde, minimum-maksimum normalizasyon tekniğine göre daha iyi performans göstermesinin nedeni, aykırı değerlerin ön planda olmadığı varsayımı ile olabilir.

Minimum-maksimum normalizasyon tekniği ile birlikte çeşitli filtreleme teknikleri değerlendirildiğinde, en iyi performans gösteren senaryo EMA filtreleme tekniği ile SN8 olarak belirlenmiştir. Bu senaryoda SN8 için hesaplanan RMSE değeri 15,32'dir. Diğer bir incelemede ise z-skoru normalizasyon tekniği ile birlikte çeşitli filtreleme teknikleri değerlendirilmiş ve en iyi performans gösteren senaryo SG filtreleme tekniği ile SN10 olarak belirlenmiştir. Hesaplanan RMSE değeri 13,57 elde edilerek tüm senaryolar arasından en iyi performans gösteren senaryo olmuştur. Çin'de gerçekleştirilen bir otoban tünelleri araştırmasında [76], otoban tünellerinin sağlık takibi için kullanılan dört farklı sensör üzerinde bir çalışma gerçekleştirilmiştir. Bu sensörler yüzey çatlak ölçer, yüzey gerinim ölçer (strain gauges), lazer mesafe bulucu ve hidrostatik seviye ölçerdir. Elde edilen veriler, çeşitli filtreleme ve gürültü azaltma teknikleri üzerinde karşılaştırılarak değerlendirilmiştir. Uçaklar özelinde düşünüldüğünde, özellikle yüzey gerinimi veya çatlak ölçen sensörler, uçak yapısal sağlık takibi için yaygın olarak kullanılmaktadır. Bu çalışma, uçaklardaki gürültü tipleri ne olursa olsun, benzer sensörleri kullanarak yapılan bir kıyaslama üzerine odaklanmıştır. Gerinim ölçen sensörler üzerinde gerçekleştirilen filtreleme işlemleri incelendiğinde, EMA filtresine kıyasla SG filtresinin daha düşük RMSE değerine sahip olduğu gözlemlenmiştir. Ayrıca, bu çalışma dalgacık dönüşümü ile SG filtresini

birleştirek daha yüksek performans elde edilmesini sağlamıştır. Bu bağlamda, sensör verilerinin işlenmesi ve gürültü azaltma tekniklerinin uygulanmasıyla ilgili yapılan kıyaslama çalışması, özellikle uçaklardaki yapısal sağlık izleme sistemleri için değerli bir referans oluşturabilir.

SG filtresinin etkili olduğu bir başka çalışmada [77] ise elektrik sistemlerindeki devre kesicilerin kalan elektriksel ömür tahmini üzerinedir. Bu alandaki bir çalışmada, devre kesicilerin kalan ömürlerini tahmin etmek amacıyla belirli bir test ortamında voltaj, akım gibi elektriksel karakteristik parametreler kullanılmış ve bu veriler üzerinde SG filtresi uygulanmıştır. İşlenmiş veriler LSTM modeli ile eğitilerek başarılı tahminler yapıldığı RMSE metriğini de içeren çeşitli performans metrikleri ile gösterilmiş ve belirtilmiştir.

EMA ve SG teknikleri ile z-skoru normalizasyon tekniğinin uygulandığı senaryolar (SN10 ve SN12), minimum-maksimum tekniğini ile birlikte uygulandığı senaryolara (SN6 ve SN8) kıyasla LSTM modelinin daha iyi performans gösterdiği görülmüştür. Ancak, dalgacık dönüşümü tekniği ile z-skoru normalizasyonunun uygulandığı senaryoda (SN11), diğer filtreleme tekniklerinde olduğu gibi, LSTM modeli üzerinde beklenen performans artışını göstermediği gözlemlenmiştir. Şaşırtıcı bir şekilde, bu durum minimum-maksimum normalizasyon yöntemiyle birlikte uygulanan senaryoda (SN7) daha iyi sonuçlar elde edilmiştir. Bu durumun altında yatan nedenlerin daha ayrıntılı bir şekilde incelenmesi gereklidir. Dalgacık dönüşümü, veri setinin frekans bileşenlerini analiz etmek için kullanılan bir tekniktir. Z-skoru normalizasyon, verilerin ortalamasını sıfıra ve standart sapmasını bir birime getirerek çalışır. Bu durum, verilerin dağılımının normal bir dağılıma daha yakın olmasını sağlar. Ancak, dalgacık dönüşümü sonrası elde edilen verilerdeki özel yapı, z-skoru normalizasyon tekniğinin etkinliğini azaltabilir. Öte yandan, minimum-maksimum normalizasyon yöntemi, verileri belirli bir aralığa sıkıştırarak çalışır. Dalgacık dönüşümü sonrası elde edilen verilerin bu yöntemle daha iyi performans göstermesi, özellikle belirli bir aralık içindeki önemli bilgilerin vurgulanmasına bağlı olabilir.

Havacılık sektöründe PHM uygulamalarının yaygınlaşabilmesi için, tüm uçak alt sistemlerinde kullanılacak maliyet etkin veri tabanlı prognostik yaklaşımı belirlemek amacıyla veri ön işleme adımları ve teknikleri üzerinde kapsamlı kıyaslamalar yapılmalıdır. Bu kıyaslamalar, uçak sistemlerinin benzer sensör

verilerine göre gruplandırılması ve her grup için ilgili veri setleri kullanılarak gerçekleştirilebilir. Elektrik, elektronik, mekanik ve elektromekanik bileşenlerin çoğunlukla bulunduğu uçak sistemlerinin ayrı birer grup olacağı varsayımı ile uçak motoru, elektrik sistemi, aviyonik sistemler ve yapısalılar için yapılan çalışmalar incelenmiştir. Bu sistemler için en iyi performans gösterecek veri ön işleme adımları ve teknikleri ayrı ayrı belirlenebilirse, benzer bileşenlere sahip tüm uçak sistemleri için de pratik bir şekilde uygulanabilir. Örneğin, aviyonik sistemler için yapılan geniş kapsamlı bir çalışma, elektronik bileşenlerin RUL tahminleri ile ilgili çeşitli tekniklerin karşılaştırılmasıyla elde edilen bulgular, elektronik bileşenlerin yoğunlukta olduğu tüm uçak sistemleri için uygulanabilir. Benzer şekilde, rulmanlar için geliştirilen ortak bir veri tabanlı prognostik çalışma, tüm mekanik sistemlerde kullanılabilir genel bir çözüm sağlayabilir. Özellikle filtreleme tekniklerinin seçiminde, uçaktaki farklı bölgelerin dikkate alınması da önemlidir. Örneğin, motor bölgesindeki sıcaklık sensörünün gürültü tipi ile kabindeki sıcaklık sensörünün gürültü tipi farklı olacaktır. Bu nedenle, uçaktaki bölgelerin ayırımına göre özelleştirilmiş teknikler veya filtreleme parametre ayarları belirlenebilir.

## 5.4 Sonuç

LSTM ağları, RUL tahmini için güçlü araçlar olarak ortaya çıkmıştır; ancak performansları girdi verilerinin kalitesinden önemli ölçüde etkilenebilir. Bu çalışmada, yaygın olarak kullanılan C-MAPSS veri seti üzerinde farklı veri ön işleme tekniklerinin birlikte veya ayrı ayrı uygulandıklarında LSTM model performansı üzerindeki etkisini araştırdık. Çeşitli veri ön işleme kombinasyonlarının LSTM modelinin performansı üzerindeki etkisi sistematik olarak değerlendirildi. Sonuçlar, doğrudan ham veri kullanımının optimumun altında performans sağladığını, buna karşılık normalizasyon tekniklerinin kullanılmasının modelin performansını tutarlı bir şekilde artırdığını gösterdi. Z-skoru normalizasyon tekniği ile SG filtresinin birlikte uygulandığı senaryo, en düşük RMSE ve en yüksek PCC değerlerine ulaşarak en iyi performansı sergiledi.

Farklı veri ön işleme adımlarının çeşitli kombinasyonlarının LSTM üzerinde beklenmedik performans değişikliklerine neden olduğu gözlemlendi. Bulgular, filtreleme tekniklerinin veya normalizasyon tekniklerinin birlikte farklı kombinasyonlar halinde uygulanmasının model performansı üzerinde farklı etkilere

sahip olabileceğini göstermektedir. Bu nedenle, farklı veri ön işleme adımlarında kullanılacak tekniklerin seçiminde kombinasyonlar halinde kapsamlı bir kıyaslama yapılmasının gerekliliği ortaya çıkmaktadır. Gelecek çalışmalar için, bu kıyaslamaların yapılması, PHM konseptinin tüm uçak sistemlerinde belirlenebilmesi için veri madenciliği konseptinin de belirlenmesi büyük önem taşımaktadır. Mevcut teknikler için yapılacak kapsamlı veri ön işleme kıyaslamaları, havacılık endüstrisindeki çeşitli alt sistemler için genel bir çözüm sunarak maliyet etkinliği ve uygulanabilirliği açısından önemli avantajlar sağlayabilir. Sonuç olarak, elde edilen bulgular, havacılık endüstrisinde PHM konseptinin oluşturulmasında en önemli adımlardan biri olan veri madenciliği yaklaşımının netleştirilmesi gerekliliğine vurgu yapmaktadır.



- [1] C. M. Ezhilarasu, “The application of reasoning to aerospace Integrated Vehicle Health”, *Progress in Aerospace Sciences*, vol.105, pp. 60-73, 2019.
- [2] BOEING, [https://www.boeing.com/news/frontiers/archive/2006/august/ts\\_sf09.pdf](https://www.boeing.com/news/frontiers/archive/2006/august/ts_sf09.pdf) (accessed Dec. 25, 2023).
- [3] Dr. Neal N. McCollom and E.R. Brown, “PHM on the F-35 Fighter”, in *IEEE Conference on Prognostics and Health Management (ICPHM)*, 2011, pp.1-10.
- [4] I. Jennions, “Chapter 14 Insights on IVHM Implementation at Airbus”, in *Integrated Vehicle Health Management: Implementation and Lessons Learned*, SAE, pp. 153-164, 2015.
- [5] A. K. Koschlik, “Towards an Integrated Vehicle Health Management for Maintenance of Unmanned Air Systems”, in *International Conference on Unmanned Aircraft Systems (ICUAS)*, 2023, pp. 463-470.
- [6] R. Laird, “The Sikorsky Approach to Global Fleet Management and Support: Lessons Learned for Evolving Military Programs”, <https://sldinfo.com/2018/02/the-sikorsky-approach-to-global-fleet-management-and-support-lessons-learned-for-evolving-military-programs/>, (accessed Nov. 25, 2023).
- [7] J. Hale, “Boeing 787”, [https://www.boeing.com/commercial/aeromagazine/articles/qtr\\_4\\_06/AERO\\_Q406\\_article4.pdf](https://www.boeing.com/commercial/aeromagazine/articles/qtr_4_06/AERO_Q406_article4.pdf), (accessed Dec. 31, 2023).
- [8] M. A. Chao, C. Kulkarni and K. Goebel, “Fusing physics-based and deep learning models for prognostics”, *Reliability Engineering and System Safety*, vol. 217, no. 107961, pp. 1-18, 2022.
- [9] K. Akkad and D. He, “A Hybrid Deep Learning Based Approach for Remaining Useful Life Estimation”, in *IEEE International Conference on Prognostics and Health Management (ICPHM)*, 2019, pp. 1-6.
- [10] A. Hess, M. G. Calvello and P. Frith, “Challenges, Issues, and Lessons Learned Chasing the “Big P”: Real Predictive Prognostics Part 1”, in *IEEE Aerospace Conference*, 2005, pp. 3610 – 3619.

- [11] E. M. Olariu and R. Portase, "Predictive Maintenance- Exploring strategies for Remaining Useful Life (RUL) prediction", in *IEEE 18th International Conference on Intelligent Computer Communication and Processing*, 2022, pp. 3-8.
- [12] M. A. Kızrak ve B. Bolat, "Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım", *Bilişim Teknolojileri Dergisi*, c. 12, sy. 2, ss. 103-109, 2019.
- [13] X. Liu, "A Hybrid Method of Remaining Useful Life Prediction for Aircraft Auxiliary Power Unit", *IEEE Sensors Journal*, vol. 20, no. 14, pp. 7848- 7858, 2020.
- [14] A. Chaturvedi, "Performance assessment and RUL prediction of power converters under the multiple components degradation", *Microelectronics Reliability*, vol. 144, no. 114958, pp. 1-14, 2023.
- [15] D. K. B. Kulevome, "A Hierarchical PHM Framework for Phased Array Radar Systems", *Progress in Electromagnetics Research M*, vol. 121, pp. 83-93, 2023.
- [16] Z. Wang and G. Zhang, "A remaining useful life prediction method for gyroscope based on LSTM", in *International Conference on Cyber-Physical Social Intelligence*, 2023, pp. 327-332.
- [17] D. Dong, X. Y. Li and F. Q. Sun "Life Prediction of Jet Engines Based on LSTM-Recurrent Neural Networks", in *Prognostics and System Health Management Conference*, Harbin, 2017, pp. 1-6.
- [18] K. Zhu and C. Zhang, "Data-driven RUL Prediction of High-speed Railway Traction System Based on Similarity of Degradation Feature", in *CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes*, 2019, pp. 292-297.
- [19] Y. Z. Zhang and R. Xiong, "A LSTM-RNN method for the lithium-ion battery remaining useful life prediction", in *Prognostics and System Health Management Conference*, Harbin, 2017, pp. 1-4.
- [20] J. Cui and Y. Wang, "Prediction of Aeroengine Remaining Useful Life Based on SE-BiLSTM", in *34th Chinese Control and Decision Conference*, 2022, pp. 1781-1786.
- [21] S. B. Ramezani, L. Cummins, B. Killen, R. Carley, A. Amirlatifi, S. Rahimi, M. Seale and L. Bian, "Scalability, Explainability and Performance of Data-Driven

Algorithms in Predicting the Remaining Useful Life: A Comprehensive Review”, *IEEE Reliability Society Section*, vol. 11, pp. 41741- 41769, 2023.

[22] O, Güler, “Turbofan motorlarının kestirimci bakımında makine öğrenimi algoritmaları performanslarının karşılaştırılması”, *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, c.13, sy. 1, ss. 99-106, 2023.

[23] F. T. Lima, “A Large Comparison of Normalization Methods on Time Series”, *Big Data Research*, vol. 34, no. 100407, pp. 1-15, 2023.

[24] N. Singh and P. Singh, “Exploring the effect of normalization on medical data classification”, in *International Conference on Artificial Intelligence and Machine Vision*, 2021, pp. 1-5.

[25] J. Baek, J. Choi and H. Jung, “Filtering Correction Method and Performance Comparison for Time Series Data”, *Journal of information and communication convergence engineering*, vol. 20, no. 2, pp. 125-130, 2022.

[26] S. Kumari, N. Kumar and P. S. Rana, “Comparative Performance Study of Different Filtering Techniques with LSTM for the Prediction of Power Consumption in Smart Grid”, *IETE Journal of Research*, pp. 1-18, 2023.

[27] X. Wang, M. Pan and C. Xia, “Water Level Data Preprocessing Method Based on Savitzky-Golay Filter”, in *Proceedings of the International Conference on Modeling, Simulation and Big Data Analysis*, 2019, pp.288-294.

[28] L. Wang and X. Wang, “Data-driven SOH Estimation of Lithium-ion Batteries Based on Savitzky-Golay Filtering and SSA-SVR Model”, in *4th International Conference on Smart Power & Internet Energy Systems*, 2022, pp.1856-1861.

[29] L. Sun, N. Lu and X. Meng, “Equipment Health State Assessment Based on MIC-XGBoost”, in *13th Asian Control Conference*, 2022, pp. 823-828.

[30] L. Honglin and J. Wang, “Based on Wavelet Threshold Denoising-LDA and Bilstm Aircraft Engine Life Prediction”, in *2nd International Conference on Computer, Remote Sensing and Aerospace*, 2022, no. 2410, pp. 1-10.

[31] A. Rai and S.H. Upadhyay, “The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings”, *Measurement*, vol. 111, pp. 397-410, 2017.

- [32] Harender and R. K. Sharma, "EEG Signal Denoising based on Wavelet Transform", in *International Conference on Electronics, Communication and Aerospace Technology*, 2017, pp. 758-761.
- [33] H. K. Sevindir, S. Çetinkaya ve Ö. Şaylı, "EKG Sinyalinden Doğru Kalp Atım Hızı Algılama İçin Dalgacık Dönüşümü Tabanlı Gürültü Giderme", *Tıp Teknolojileri Ulusal Kongresi*, 2015, ss. 18-21.
- [34] M. Kopuru, S. Rahimi and K. T. Baghaei, "Recent Approaches in Prognostics: State of the Art", in *Int'l Conf. Artificial Intelligence*, 2019, pp. 358-365.
- [35] L. Nie, S. Xu, L. Zhang, Y. Yin, Z. Dong and X. Zhou, "Remaining Useful Life Prediction of Aeroengines Based on Multi-Head Attention Mechanism", *Mechanism Machines*, vol. 10, no. 7, pp. 1-14, 2022.
- [36] H. Yan, H. Zuo, J. Sun, D. Zhou and H. Wang, "Two-Stage Degradation Assessment and Prediction Method for Aircraft Engine Based on Data Fusion", *International Journal of Aerospace Engineering*, vol. 2021, no. 1, pp. 1-16, 2021.
- [37] Z. Ye and J. Yu, "Health condition monitoring of machines based on long short-term memory convolutional autoencoder", *Applied Soft Computing*, vol. 107, no. 107379, pp. 1-14, 2021.
- [38] N. Costa and L. Sánchez, "Variational encoding approach for interpretable assessment of remaining useful life estimation", *Reliability Engineering & System Safety*, vol.222, no. 108353, pp. 1-12, 2022.
- [39] J. Han, M. Kamber and J. Pei, "the book of Data Mining: Concepts and Techniques", Morgan Kaufmann, 2011.
- [40] J. Li and Y. Jia, "Remaining Useful Life Prediction of Turbofan Engines Using CNN-LSTM-SAM Approach", *IEEE Sensors Journal*, vol. 23, no. 9, pp. 10241-10251, 2023.
- [41] I. Pater and M. Mitici, "Developing health indicators and RUL prognostics for systems with few failure instances and varying operating conditions using a LSTM autoencoder", *Engineering Applications of Artificial Intelligence*, vol. 117, no. 105582, pp. 1-12, 2023.

- [42] D. Ruan and Y. Wu, "Remaining Useful Life Prediction for Aero-Engine Based on LSTM and CNN", in *33rd Chinese Control and Decision Conference*, 2021.
- [43] Y. Zhu and Z. Liu, "Aircraft engine remaining life prediction method with deep learning", in *International Conference on Artificial Intelligence and Computer Information Technology*, 2022, pp. 1-6.
- [44] N. H. Kim, D. An and J. H. Choi, "the book of Prognostics and Health Management of Engineering Systems", Springer International Publishing AG, 2017.
- [45] A. Regattieri, "An innovative method to optimize the maintenance policies in an aircraft: General framework and case study", *Journal of Air Transport Management*, vol. 44-45, pp. 8-20, 2015.
- [46] T. Zaman, "Estimation of Economic Effectiveness of HUMS equipped AH-64 Aircraft: An ROI Approach", in *AHS 72nd Annual Forum & Technology Display*, 2016, pp.1-9.
- [47] M. Revor and E. Bechhoefer, "Rotor Track and Balance Cost Benefit Analysis and Impact on Operational Availability", in *American Helicopter Society 60th Annual Forum*, Baltimore, 2004, pp. 1-11.
- [48] A. Baghchehsara, T. Odinet, J. Robbe and H. Meyer, "Identification and Interpretation of Integrated Vehicle Health Management (IVHM) Generic Architecture and a Case Study", in *Deutscher Luft- und Raumfahrtkongress*, Bremen, 2016, pp. 1-7.
- [49] J. Dunsdon, "The Use of On-Board Condition Monitoring, Usage Monitoring, Diagnostics, Prognosis, and Integrated Vehicle Health Management to Improve Aircraft Availability and Mission Reliability", in *RTO AVT-144 workshop on Enhanced Aircraft Platform Availability Through Advanced Maintenance Concepts and Technologies*, 2006, pp. 1-22.
- [50] S. Chang and Y. Wang, "Civil aircraft IVHM system analysis using model based system engineering", in *Second International Conference on Reliability Systems Engineering*, Beijing, 2017, pp. 1-5.

- [51] O. Benedettini, T. S. Baines, H. Lightfoot and R. M. Greenough, “State-of-the-art in integrated vehicle health management”, *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, vol. 223, no. 2, pp. 157-170, 2009.
- [52] L. Singh, Prof. N. Singh and Prof. A. Srivastava, “Integrated Vehicle Health Management System for Fighter Aircraft”, *International Journal of Scientific Research in Science and Technology*, vol. 2, no. 6, pp.120-125, 2016.
- [53] A. K. Jha, S. Nayak and N. K. Veerabhadrapa, “An Architecture for Performing Real Time Integrated Health”, in *2nd IEEE International Conference on Computational Systems and Information Technology for Sustainable Solutions*, 2017, pp. 242-246.
- [54] A. H. Kinnison, “the book of Aviation Maintenance Management”, McGraw-Hill Companies.Inc, 2012.
- [55] J. J. M. Jiménez, R. A. Vingerhoeds, B. Grabot and S. Schwartz, “An Ontology Model for Maintenance Strategy Selection and Assessment”, *Journal of Intelligent Manufacturing*, vol.34, pp.1369-1387, 2022.
- [56] V. Atamuradov and K. Medjaher, “Prognostics and Health Management for Maintenance Practitioners- Review, Implementation and Tools Evaluation”, *International Journal of Prognostics and Health Management*, vol. 8, no. 3, pp. 1-31, 2017.
- [57] I. K. Jennions, “Integrated vehicle health management: Perspectives on an emerging field”, SAE International, Pennsylvania, 2011.
- [58] R. Li, W. J.C. Verhagen, R. Curran, “Toward a Methodology of Requirements Definition for Prognostics and Health Management System to Support Aircraft Predictive Maintenance”, *Aerospace Science and Technology*, vol. 102, no. 105877, pp. 1-21, 2020.
- [59] S.Kılıç, “Herkes için Havacılık”, <https://herkesicinhavacilik.com/tag/ucak-bakim/> (Erişim tarihi Ocak 14, 2024).
- [60] J. Li and Y. Jia, “Remaining Useful Life Prediction of Turbofan Engines Using CNN-LSTM-SAM Approach”, *IEEE Sensors Journal*, vol. 23, no. 9, pp. 10241-10251, 2023.

- [61] Freepik Company, “Airplane Parts and Function”, [https://www.freepik.com/premium-vector/airplane-parts-functions-illustration\\_7291049.htm#position=1](https://www.freepik.com/premium-vector/airplane-parts-functions-illustration_7291049.htm#position=1) (accessed Dec 23, 2023).
- [62] ARP6461, SAE, “Guidelines for Implementation of Structural Health Monitoring on Fixed Wing Aircraft”, Aerospace Recommended Practice, 2013.
- [63] SAE International, “Perspectives on Integrating Structural Health Monitoring Systems into Fixed-Wing Military Aircraft”, Aerospace Information Report, 2019.
- [64] BOEING, <https://787updates.newairplane.com/787-Electrical-Systems/787-electrical-system> (accessed Dec 23, 2023)
- [65] D. W. Brown, “Electronic prognostics - A case study using global positioning system (GPS)”, *Microelectronics Reliability*, vol. 47, no.12, pp. 1874-1881, 2007.
- [66] J. V. Wagenen, <https://www.aviationtoday.com/2015/06/22/rockwell-collins-and-gps-source-demonstrate-m-code-gps-receiver-in-d3/> (accessed Dec 23, 2023).
- [67] A. Saxena, K. Goebel, D. Simon and N. Eklund, “Damage Propagation Modeling for Aircraft Engine Run-to-Failure Simulation”, in *2008 International Conference on Prognostics and Health Management*, Denver, 2008, pp.1-9.
- [68] C. Teubert, [https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6/about\\_data](https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6/about_data) (accessed May 1, 2023).
- [69] S. Hochreiter and J. Schmidhuber, “Long Short-Term Memory”, *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [70] D. Ruan, Y. Wu, “Remaining Useful Life Prediction for Aero-Engine Based on LSTM and CNN”, in *33rd Chinese Control and Decision Conference*, 2021, pp. 6706- 6712.
- [71] A. Savitzky and M. J. E. Golay, “Smoothing and differentiation of data by simplified least squares procedures”, *Analytical Chemistry*, vol. 36, no. 8, pp. 1627–1639, 1964.
- [72] Pywavelets, <https://wavelets.pybytes.com/wavelet/db4/> (accessed Jan 20, 2024).
- [73] I. Daubechies, “the textbook of Ten Lectures on Wavelets, Society for Industrial and Applied Mathematics”, SIAM, 1992.

- [74] W. Hu and S. Zhao, “Remaining useful life prediction of lithium-ion batteries based on wavelet denoising and transformer neural network”, *Front. Energy Res.*, vol. 10, no. 3389, pp. 1-13, 2022.
- [75] A. R. de Miranda, “Recurrent Neural Network Based on Statistical Recurrent Unit for Remaining Useful Life Estimation”, in *8th Brazilian Conference on Intelligent Systems*, 2019, pp. 425-430.
- [76] N. Zhao, J. Wei, Z. Long, C. Yang, J. Bi, Z. Wan and S. Dong, “An Integrated Method for Tunnel Health Monitoring Data Analysis and Early Warning: Savitzky–Golay Smoothing and Wavelet Transform Denoising Processing”, *Sensors*, vol. 23, no. 7460, pp. 1-21, 2023.
- [77] J. Ouyang and C. Chi, “The Prediction of Residual Electrical Life in Alternating Current Circuit Breakers Based on Savitzky-Golay-Long Short-Term”, *Sensors*, vol. 23, no. 6860, pp. 1-26, 2023.
- [78] T. Berghout and M. Benbouzid, “A Systematic Guide for Predicting Remaining Useful Life with Machine Learning”, *Electronics*, vol. 11, no. 1125, pp. 1-31, 2022.

## TEZDEN ÜRETİLMİŞ YAYINLAR

---

### Makaleler

1. M. Erdoğan ve M. Mercimek, “A Comparative Study on Data Pre-Processing Techniques for Remaining Useful Life Prediction of Turbofan Engines”, *TIJMET*, c. 6, sy. 2, ss. 50–58, 2023.

