

**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ İLE TURBOFAN MOTORLARIN  
GERİYE KALAN YARARLI ÖMRÜNÜN  
TAHMİNLEMESİ**

**Hazırlayan  
Seda Nur BOZKURT**

**Danışman  
Doç. Dr. Selda KAPAN ULUSOY**

**Yüksek Lisans Tezi**

**Mayıs 2024  
KAYSERİ**



**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**MAKİNE ÖĞRENMESİ İLE TURBOFAN MOTORLARIN  
GERİYE KALAN YARARLI ÖMRÜNÜN  
TAHMİNLEMESİ**

**(Yüksek Lisans Tezi)**

**Hazırlayan  
Seda Nur BOZKURT**

**Danışman  
Doç. Dr. Selda KAPAN ULUSOY**

**Mayıs 2024  
KAYSERİ**

## **BİLİMSEL ETİĞE UYGUNLUK**

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Seda Nur BOZKURT

İmza



**“Makine Öğrenmesi ile Turbofan Motorların Geriye Kalan Yararlı Ömrünün Tahminlemesi”** adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

**Hazırlayan**

Seda Nur BOZKURT

**Danışman**

Doç. Dr. Selda KAPAN ULUSOY

**Endüstri Mühendisliği ABD Başkanı**

Prof. Dr. Lale ÖZBAKIR

## TEŞEKKÜR

Bana çalışmalarım süresince her türlü yardımı ve fedakârlığı sağlayan, çalışma süresince bilgi ve tecrübesi ile bana yol gösteren, tez tanışmanım sayın Doç. Dr. Selda Kapan Ulusoy'a, yüksek lisansım süresince maddi ve manevi desteğini esirgemeyen her zaman yanımda olan sevgili eşim Alparslan Bozkurt'a, her koşulda bana inanan ve yanımda olan canım annem ve babama sonsuz teşekkürlerimi sunarım.

Seda Nur BOZKURT

Mayıs 2024, KAYSERİ

# MAKİNE ÖĞRENMESİ İLE TURBOFAN MOTORLARIN GERİYE KALAN YARARLI ÖMRÜNÜN TAHMİNLEMESİ

Seda Nur BOZKURT

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Mayıs 2024

Danışman: Doç. Dr. Selda KAPAN ULUSOY

## ÖZET

Bakım planlaması hem makine hem de işletme verimliliğinde çok önemlidir. Ancak havacılık sanayii alanında uçak motor vb. parça bileşenlerinin bakımı uçuş güvenliğini etkilediği için hayati önem taşımaktadır. Geriye kalan faydalı ömür, bu bakım planının etkin ve ekonomik yapılabilmesi için en önemli değişkendir. Bu çalışmada arıza meydana gelmeden bakım ve onarımın yapılması ve kayıpların yaşanmaması için kalan faydalı ömrü tahmin etmeyi amaçlıyoruz.

Veri seti olarak turbofan motorların belirli koşullar altında çalışma durumlarını gösteren Doğrulama için Ulusal Havacılık ve Uzay Dairesi (NASA) C-MAPSS veri seti kullanılmıştır. Turbofan motorların geriye kalan faydalı ömrünü tahmin etmek için eğitim seti Google Colab'ta Python kodlaması yapılarak makine öğrenim yöntemlerinin en iyi parametre değerleri tespit edilerek , bu modeller eğitilmiştir. Test veri setinde ise kalan ömürler tahmin edilerek kurulan modellerin performans değerleri hesaplanmış ve değerlendirilmiştir.

**Anahtar Kelimeler:** Kestirimci Bakım, Kalan Faydalı Ömür, C-MAPPS, Makine Öğrenim Yöntemleri

# **ESTIMATE THE REMAINING USEFUL LIFE OF TURBOFAN ENGINES USING MACHINE LEARNING**

**Seda Nur BOZKURT**

**Erciyes University, Graduate School of Natural and Applied Sciences**

**Master Thesis, May 2024**

**Supervisor: Assoc. Prof. Dr. Selda KAPAN ULUSOY**

## **ABSTRACT**

Maintenance planning is very important in both machine and operating efficiency. However, in the field of aviation industry, aircraft engines etc. Maintenance of part components is vital as it affects flight safety. The remaining useful life is the most important variable for making this maintenance plan effective and economical. In this study, we aim to estimate the remaining useful life in order to perform maintenance and repair before failure occurs and to avoid losses.

As a data set, the National Aeronautics and Space Administration (NASA) C-MAPSS data set was used for verification, which shows the operating states of turbofan engines under certain conditions. In order to estimate the remaining useful life of turbofan engines, these models were trained by determining the best parameter values of machine learning methods by using Python coding in the training set Google Colab. In the test data set, the remaining lifetimes were estimated and the performance values of the established models were calculated and evaluated.

**Key Words:** Predictive Maintenance, Remaining Useful Life, C-MAPSS, Machine Learning Methods

## İÇİNDEKİLER

### MAKİNE ÖĞRENMESİ İLE TURBOFAN MOTORLARIN GERİYE KALAN YARARLI ÖMRÜNÜN TAHMİNLEMESİ

|                               |      |
|-------------------------------|------|
| BİLİMSEL ETİĞE UYGUNLUK ..... | ii   |
| YÖNERGEYE UYGUNLUK .....      | iii  |
| KABUL VE ONAY .....           | iv   |
| TEŞEKKÜR .....                | v    |
| ÖZET .....                    | vi   |
| ABSTRACT .....                | vii  |
| İÇİNDEKİLER .....             | viii |
| KISALTMALAR .....             | x    |
| TABLolar LİSTESİ .....        | xii  |
| ŞEKİLLER LİSTESİ .....        | xiii |
| GİRİŞ .....                   | 1    |

## 1. BÖLÜM

### GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

|                                             |    |
|---------------------------------------------|----|
| 1.1. Plansız Bakım .....                    | 3  |
| 1.2. Planlı Bakım .....                     | 4  |
| 1.2.1. Önleyici Bakım .....                 | 4  |
| 1.2.2. Kestirimci Bakım .....               | 5  |
| 1.3. Arıza Tahmini .....                    | 8  |
| 1.4. Kalan Faydalı Ömür .....               | 9  |
| 1.4.1. Fiziğe Dayalı RUL Tahmini .....      | 10 |
| 1.4.2. Veri Tabanlı RUL Tahmini .....       | 11 |
| 1.4.3. Hibrit Tabanlı RUL Tahmini .....     | 11 |
| 1.5. Literatür Taraması .....               | 12 |
| 1.6. Gaz Türbinli Motorlar .....            | 17 |
| 1.6.1. Turbofan Motor Parametreleri .....   | 19 |
| 1.6.1.1. Birincil Motor Parametreleri ..... | 20 |
| 1.6.1.2. İkincil Motor Parametreleri .....  | 20 |
| 1.6.2. Arıza Sebepleri .....                | 20 |

## 2. BÖLÜM

### YÖNTEM VE MATERYAL

|                                               |    |
|-----------------------------------------------|----|
| 2.1. Veri Seti .....                          | 22 |
| 2.2. Veri Ön İşleme .....                     | 25 |
| 2.3. Özellik Seçimi .....                     | 26 |
| 2.4. Makine Öğrenim Yöntemleri .....          | 27 |
| 2.4.1. Doğrusal Regresyon (LR) .....          | 27 |
| 2.4.2. Destek Vektör Regresyonu (SVR) .....   | 28 |
| 2.4.3. Karar Ağacı (DT) .....                 | 28 |
| 2.4.4. Rassal Orman (RF) .....                | 28 |
| 2.4.5. Yapay Sinir Ağları (ANN) .....         | 28 |
| 2.4.6. XGBoost .....                          | 29 |
| 2.5. Performans Değerlendirme Ölçütleri ..... | 29 |

## 3. BÖLÜM

### BULGULAR

|                               |    |
|-------------------------------|----|
| 3.1. Uygulama Sonuçları ..... | 31 |
|-------------------------------|----|

## 4. BÖLÜM

### SONUÇ

|                 |    |
|-----------------|----|
| 4.1.Sonuç ..... | 40 |
| KAYNAKÇA .....  | 42 |
| ÖZGEÇMİŞ .....  | 48 |

## KISALTMALAR

|                |                                                     |
|----------------|-----------------------------------------------------|
| <b>ACLSTM</b>  | : Otomatik Genişletilebilen Uzun-Kısa Süreli Bellek |
| <b>ANN</b>     | : Yapay Sinir Ağı                                   |
| <b>CLSTM</b>   | : Evrişim Tabanlı Uzun-Kısa Süreli Bellek           |
| <b>C-MAPSS</b> | : Ticari Modüler Aero-Tahrik Sistemi Simülasyonu    |
| <b>CNN</b>     | : Evrişimsel Sinir Ağı                              |
| <b>DNN</b>     | : Derin Sinir Ağı                                   |
| <b>DT</b>      | : Karar Ağacı                                       |
| <b>EGT</b>     | : Egzoz Gazı Sıcaklığı                              |
| <b>EPR</b>     | : Motor Basınç Oranı                                |
| <b>HMM</b>     | : Gizli Markov Modeli                               |
| <b>HPC</b>     | : Yüksek Basınç Kompresörü                          |
| <b>HPT</b>     | : Yüksek Basınç Türbin                              |
| <b>HR</b>      | : Tehlike Oranı                                     |
| <b>HSMM</b>    | : Yarı Gizli Markov Modeli                          |
| <b>ILSTMC</b>  | : Kümelemeli Çok Aşamalı Uzun-Kısa Süreli Bellek    |
| <b>KGHM</b>    | : Bilgi Güdümlü Hibrit Model                        |
| <b>LPC</b>     | : Alçak Basınç Kompresörü                           |
| <b>LPT</b>     | : Alçak Basınç Türbin                               |
| <b>LR</b>      | : Doğrusal Regresyon                                |
| <b>LSTM</b>    | : Uzun-Kısa Süreli Bellek Ağı                       |
| <b>MAE</b>     | : Ortalama Mutlak Hata                              |
| <b>MCLSTM</b>  | : Çoklu Evrişimsel Uzun-Kısa Süreli Bellek Ağı      |
| <b>MSCNN</b>   | : Çok Ölçekli Evrişimli Sinir Ağı                   |
| <b>MSE</b>     | : Ortalama Kare Hatası                              |
| <b>NASA</b>    | : Ulusal Havacılık ve Uzay Dairesi                  |
| <b>PSO</b>     | : Parçacık Sürü Optimizasyonu                       |
| <b>R2</b>      | : Belirlilik Katsayısı                              |
| <b>RF</b>      | : Rassal Orman                                      |
| <b>RMS</b>     | : Kök Ortalama Kare                                 |
| <b>RMSE</b>    | : Kök Ortalama Kare Hatası                          |
| <b>RUL</b>     | : Kalan Faydalı Ömür                                |

**SVR** : Destek Vektör Regresyonu  
**TFR** : Zaman Frekans Gösterimi  
**YSA** : Yapay Sinir Ağı



## TABLÖLAR LİSTESİ

|          |                                                               |    |
|----------|---------------------------------------------------------------|----|
| Tablo 1. | Seçilmiş Öznitelikler .....                                   | 27 |
| Tablo 2. | LR Modeli Sonuçları .....                                     | 34 |
| Tablo 3. | SVR Modeli Sonuçları .....                                    | 35 |
| Tablo 4. | DT Modeli Sonuçları .....                                     | 36 |
| Tablo 5. | RF modeli Sonuçları .....                                     | 36 |
| Tablo 6. | ANN Modeli Sonuçları .....                                    | 37 |
| Tablo 7. | XGBoost Modeli Sonuçları .....                                | 38 |
| Tablo 8. | Tüm Modellerin Sonuçları .....                                | 39 |
| Tablo 9. | Farklı Kırpma Değeri Seçilirse Tüm Modellerin Sonuçları ..... | 39 |

## ŞEKİLLER LİSTESİ

|           |                                                                                                                    |    |
|-----------|--------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.  | Gaz Türbinli Motor Kısımları .....                                                                                 | 19 |
| Şekil 2.  | Eğitim Setine RUL Değeri Sütunu Eklenmesi.....                                                                     | 25 |
| Şekil 3.  | Korelasyon Isı Matrisi.....                                                                                        | 26 |
| Şekil 4.  | RUL ve Sensörler Arasındaki İlişkinin Grafikleri .....                                                             | 33 |
| Şekil 5.  | Doğrusal RUL ve s_12 Sensörü Arasındaki İlişki .....                                                               | 34 |
| Şekil 6.  | LR Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik.....       | 35 |
| Şekil 7.  | SVR Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik .....     | 35 |
| Şekil 8.  | DT Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik.....       | 36 |
| Şekil 9.  | RF Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik.....       | 37 |
| Şekil 10. | ANN Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik .....     | 38 |
| Şekil 11. | XGBoost Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik ..... | 38 |

## GİRİŞ

Teknolojideki ilerlemeler birçok alanda gelişmeleri beraberinde getirmiş ve insan hayatını yakından etkilemiştir. İnsanların ihtiyaçları teknolojinin gelişmesiyle doğru orantılı olarak artmış ve insanlık ihtiyaçlarını karşılamak için daha iyisini arama arayışına girmiştir. Artan ihtiyaçlar, yeni ihtiyaçları meydana getirmiş ve sürekli artan talep endüstriyi meydana getirmiştir. Sanayi devrimi ile buhar gücüyle çalışan makinelerin ortaya çıkması endüstrideki gelişmeleri hızlandırmıştır. Endüstrileşmedeki gelişmeler ve artan insan nüfusu daha fazla ihtiyaca daha fazla ihtiyaç ise daha fazla üretime sebep olmuştur. Sanayi devrimiyle birlikte insan gücünün yerini makineler almış ve makineleşme hızlanmıştır.

Makineler insan hayatına girdiğinden bugüne kadar, makinelerin daha verimli ve sürekli çalışabilmesi bu konuyla ilgilenenlerin öncelikli hedefleri arasındadır. Makineler veya bir araya gelerek makineyi oluşturan parçalar zamanla bozulabilir ve makinenin sürekli çalışmasına engel olabilir. Makinede meydana gelebilecek hataları önceden tahmin etmek ve ortaya çıkabilecek sonuçlara önceden tedbir alınabilmek için birçok yöntem geliştirilmiştir. Bu yöntemlerden birisi de makinenin planlanmamış arızalarının tahmini yaparak makinelerde meydana gelebilecek hataları önceden tahmin etmeye yarayan kestirimci bakım yöntemleridir. Kestirimci bakım planının yapılabilmesi için makine öğrenmesi modelleri veya fiziksel yasalara dayalı modeller kullanılarak hatanın gelecekte ne zaman ortaya çıkacağı tahmin edilmesi gerekir. İnsanlar eski zamanlardan beri kullandıkları sistemlerin ömürlerini tahmin etmeye çalışmışlardır. Örneğin tekerleğin icat edildiği dönemden itibaren arabalar kullanılmaktadır. İlk arabalar düşünüldüğünde oldukça basit bir mekanik sistemden oluşmasına karşı aks, tekerlek gibi kırılabilen, arızaya veya durmaya sebep olabilecek parçalara sahiptir. O zamanlar insanlar yolculuk başlamadan önce arabaların sağlıklı bir şekilde çalışıp çalışmadığı, değiştirilmesi gereken parçasının olup olmadığına karar verebilmek için görsel inceleme ve kişisel deneyimlerini kullanıyorlardı. Günümüzde gelişen teknolojiyle birlikte birçok yeni sistem geliştirildi.

Her amaç için farklı ve karmaşık hale gelen bu sistemlerin hangi parçasının arızalanacağına, sistemin sürekli ve güvenilir bir şekilde çalışıp çalışmayacağına karar vermek için yalnızca görsel inceleme ve deneyimi kullanmak artık mümkün değildir. Bu yüzden daha akılcı, bilimsel ve veriye dayalı bakım tahminlerinin yapılması gerekmektedir. Kestirimci bakım birçok endüstriyel alanda kullanılabilirliği ve çalışma süresini iyileştirme de etkili bir araçtır.

Bu çalışmada kestirimci bakım yöntemi kullanarak bir uçağın turbofan motorunda meydana gelebilecek arızaları önceden tahmin edebilecek bir yaklaşım oluşturmayı amaçlamaktayız. Sistemde meydana gelebilecek arızaları veriye dayalı olarak tahmin ederek sistemin sürekli ve güvenilir olarak çalışmasına olanak sağlayacağız. Böylece sistem çalışırken meydana gelebilecek olumsuzlukların önüne geçmeyi amaçlıyoruz.

Tez çalışmasının birinci bölümünde bakım çeşitleri, kalan faydalı ömür ve turbofan motorlar hakkında genel bilgiler verilmiştir. Devamında ise literatür çalışmaları incelenmiştir. İkinci bölümde kullanılacak yöntemler, veri setinin özellikleri, veri ön işleme ve veriden öznitelik seçimi hakkında bilgiler verilmiştir. Üçüncü bölümde Google Colab'ta Python kodlama dili ile makine öğrenim yöntemlerinin en iyi parametreleri değerleri bulunarak, modeller kurulup sonuçları incelenmiştir. Dördüncü bölüm sonuç kısmında ise tez değerlendirilmiştir.

## 1. BÖLÜM

### GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

Tesislerde sistemlerin istenilen koşullarda sürekli olarak çalışması amaçlanmaktadır. Fakat istemeyen durumlarda çalışma koşulları dışına çıkılabilir ve sistem istenilen performansı sergileyemez. İstenilmeyen bu durumlara karşı farklı yaklaşım türleri geliştirilmiştir. Geliştirilen yaklaşımlardan birisi de bakım yöntemleridir. Bakım, bir sistemin çalışma süresi boyunca istenilen işlevi yerine getirebileceği bir durum aralığında tutulması veya çalışabilecek duruma geri getirilmesini amaçlayan tüm idari, teknik ve yönetsel çalışmaların birleşimidir [EN13306, 2010]. Yani bakım sadece sistemi oluşturan bir parça veya uzuv üzerinde değil sistemin tamamını kapsayan bir süreçtir. Bakım yöntemleriyle üretimin kalitesi ve sürekliliği sağlanması hedeflenmektedir. Bu hedef doğrultusunda uygulanan farklı bakım modelleri mevcuttur. Bakım modelleri, genel olarak planlı ve plansız bakım olarak iki çatı altında toplanmıştır. Planlı bakım bir nevi önleyici bakım olarak adlandırılabilir ve sistem çalışır durumda gerçekleştirilebilir ve arızaların sıklığını azaltmayı amaçlamaktadır. Plansız bakım ise düzeltici bakım olarak isimlendirilebilir ve bir arıza meydana geldikten sonra uygulanır ve sistemin tekrar çalışma koşullarına getirilmesi amaçlanmaktadır [Doyen, L., & Gaudoin, O., 2011].

#### 1.1. Plansız Bakım

Bir sistem içerisinde makine veya ekipman bozulduğu ya da arıza meydana gelince yapılan bakımdır. Arıza meydana geldikten sonra sistemi tekrar belirlenen çalışma koşullarına getirerek sistemin çalışmasına devam etmesi için uygulanan tüm faaliyetleri ifade eder. Bu tür bakım yapılması gerektiğinde üretim süreci durdurulur, üretim azalır ve maliyet artar. Arıza tahmin edilemediği, zamansız bir arıza meydana geldiği için zaman kaybı fazladır. Arıza meydana gelmeden herhangi bir işlem ya da çalışma gerektirmez. Bu yöntem genellikle yeterli sayıda yedek parçası bulunan, kolay tamir edilebilen ve fazla maliyetli olmayan ekipmanlarla üretim yapan atölye ve tesislerde

uygulanmaktadır. Fakat bu bakım türünde arıza, başka parçalarında zarar görmesine neden olabilir. Bu gibi olumsuzluklardan dolayı mecbur kalınmadıkça uygulanmamaktadır [Galar, 2017], [Mital, 2014]. Plansız bakım çeşitleri bir plan dahilinde gerçekleşmediği için bir strateji oluşturmazlar. Arıza anındaki duruma bağlı olarak o an uygulanırlar. Plansız bakım düzenli bakım, arıza bakım, acil bakım, fırsatçı bakım olarak dörde ayrılır.

Düzenli bakım, ekipmanların yağlanması, temizlenmesi ve kontrol edilmesi gibi ekipmanların düzenli olarak yapılan bakım sınıfına girmektedir. Bu işlemler bir plan ve periyot aralığında gerçekleşmez. Planlı olmayan bu eylem makinaları kullanan görevlilerin gerekli gördüğü zaman aralıklarında gerçekleştirilir. Arıza ve acil bakım sadece sistemde bir arıza meydana geldiğinde uygulanır. Sistem bu bakım türleri kullanılmadan önce kesintiye uğramıştır. Acil bakım durumun önemini gösterir ve arıza sonrası bakımın önceliğini belirler [Palmer, 2013].

Bir arıza meydana geldiği durumda sistemde kesinti meydana gelmiş ve ne zaman düzeleceği tam olarak bilinmemektedir. Oluşan olumsuz durumu bir fırsata çevirerek arızaya sebep olmamış ekipmanların bakımı, onarımı veya değiştirilmesi fırsatçı bakım olarak adlandırılır [Gulati, 2009].

## **1.2. Planlı Bakım**

Bir sistem içerisinde arıza meydana gelmeden önce yapılan bakımdır. Bu bakım yöntemiyle sistemi oluşturan ekipmanların servis ömrünü uzatmak ve bozulmalarını önlemek hedeflenmektedir. Planlı bakım yöntemiyle asıl amaç sistemin sürekliliğini sağlamak ve meydana gelebilecek kesintileri en aza indirmektir. Daha önceki arıza nedenleri, deneyimler, makine öğrenmesi, fiziksel yasalar, yapay zekâ gibi araçlar kullanılarak arızaların meydana gelmeden önce alınacak önlemler veya gerekli düzenlemeleri içerir. Planlı bakım önleyici bakım ve kestirimci bakım olarak gruplandırılır [Gulati, 2009].

### **1.2.1. Önleyici Bakım**

Önleyici bakım, o anki duruma bakılmaksızın herhangi bir arıza meydana gelmeden önce ekipman ömrünün uzatılması, ekipmanların istenilen durumda çalışmasını sağlamak ve

tesislerde meydana gelebilecek kesintilerin azaltılmasını hedefleyen bir planlı bakım yöntemidir. Önleyici bakım arıza meydana gelmeden önce ekipmanların planlandığı belirli aralıklarla kontrol edilmesi ve bakımının yapılmasıdır. Genellikle bir takvim zamanına göre gerçekleştirilir. Ekipmanlarda meydana gelebilecek plansız duraksamaları azaltmak amaçlanmaktadır. Düzenli şekilde ekipmanlar kontrol edilir ve belirlenen arıza ve arızaya neden olabilecek muhtemel durumlar düzeltilir. Çalışma koşulları, makinaların eski performansı ve donanımların hangi aralıklarda bakıma alınması gerektiği göz önüne alınarak hangi zaman aralıklarında bakımının yapılacağı belirlenebilir. Bu planlamayla birlikte ekipmanlarda meydana gelebilecek çatlak, korozyon, gevşemeler, deformasyonlar, sızıntılar, aşırı ısınma, titreşim gibi zamanla ekipmanlara dahada zarar verebilecek durumların önüne geçilmiş olur. Periyodik bakım faaliyetleri genellikle, yağlama işleri, temizleme işlemleri, muayeneler, kalibrasyon, programlı onarım, revizyon ve parça değişimleridir [Gulati, 2009], [Palmer, 2013], [Campbell, 2015]. Periyodik bakım faaliyetlerinin avantajları aşağıdaki gibi sıralanabilir:

- Tesiste meydana gelebilecek üretim duruşları azalır.
- Arıza nedeniyle duruşlar kontrol edilebilir.
- Ekipman kullanılabilirlik oranı artar.
- Ekipmanın ömrü uzatılmış olur.
- Arızaya sebep olabilecek parçanın başka parçalara hasar vermesinin önüne geçilir.
- Ekipmanlar belirli aralıklarla kontrol edildiği için ekipmanlar daha verimli çalışır.
- Daha az onarım maliyetleri harcanır.
- Güvenli çalışma ortamı oluşturulur.

### 1.2.2. Kestirimci Bakım

Periyodik veya sürekli olarak sistemin izlenmesiyle ekipmanların durumunun değerlendirilmeye çalışıldığı bakım türüdür. Kestirimci bakım, gerektiğinde özel cihazlar yardımıyla yapılan gözlemler, özel muayene cihazları ve kayıt izleme sistemleriyle ekipmanların bakım ve onarım ihtiyaçlarının belirlenmesi ve planlanan uygun

zamanlarda bu faaliyetlerin gerçekleştirilmesidir. Kestirimci bakım, tesiste çalışan her bir ekipmanı takip ederek meydana gelebilecek arızaları tespit etmek ve tesislerde meydana gelebilecek plansız duruşları en aza indirmeyi amaçlamaktadır. Özel ölçüm cihazları kullanılarak ekipmanlar izlenir ve ekipmanların çalışma verileri kaydedilir. Elde edilen ölçüm verileri belirli zaman aralıklarında değerlendirilir. Ekipmanların çalışması istenilen koşullar ile kıyaslanarak sistemde bir sorunun olup olmadığı veya bir sorunun ortaya çıkıp çıkmayacağı tespit edilir. Ekipmanlardan alınan veriler ışığında parçaların ömür durumları hakkında analiz yapar. Kestirimci bakım da sistem çalışır durumdayken değerlendirmeler yapıldığı için hem tesislerin gereksiz duraksamasının önüne geçilir hem de alınan veriler ışığında ekipmanların ömürleri hakkında bilgi sahibi olunur. Ekipmanlar izlenirken, titreşim analizi, basınç, güç, nem, sıcaklık gibi veriler göz önüne alınır. Verilerde meydana gelen değişiklikler ve verilerin eğilimleri değerlendirilir. Bu veriler ışığında planlı bir bakım hazırlanır. Kestirimci bakım uygulanması sırasında teknolojiden olabildiğince yararlanması sistemde meydana gelebilecek arızaların önüne arıza meydana gelmeden önce geçmek için oldukça önemlidir. Kestirimci bakımı diğer planlı bakım türünden ayıran en önemli özelliği bakımın önceden belirlenmiş bir programdan daha çok makinenin şu anki durumuna bağlı olarak yapılmasıdır [Gulati, 2009], [Palmer, 2013], [Campbell, 2015].

Periyodik bakım ve kestirimci bakımın daha net olarak birbirinden ayrılması için şu örnek verilebilir: Çoğu kullanıcı araçlarında kullandıkları motor yağlarını 10000-15000 km civarında değiştirmektedir. Periyodik olarak değiştirilen motor yağı çalışma süresine dayanmaktadır. Yağın o anki durumu, performansı analiz edilmeden önleyici bir bakım yapılmıştır. Bu davranış periyodik bakım olarak arıza meydana gelmeden önce yapıldığı ve sistemin çalışması devam ettiği için bir sorun yoktur. Fakat bu durumu bir kestirimci bakım ile planlarsak araçta kullanılan yağın o anki durumu değerlendirilerek değişip değişmeyeceğine karar verilir, yağın durumu iyi ise yağ değişimini 15000-20000 km'ye kadar uzatılabilir. Bu örnekten de anlaşılabileceği gibi bunun gibi anlık, gerçek durumu göz önüne aldığı için kestirimci bakım kullanmak daha avantajlı duruma gelmektedir [Gulati, 2009], [Campbell, 2015].

Yukarıda değinilen örnekte olduğu gibi kestirimci bakım nicel araştırma ve performans verilerine dayalı olarak bakımı planlamaktadır. Kestirimci bakım uygun maliyetle meydana gelebilecek arızaları azaltacaktır. Ayrıca karmaşık sistemlerin daha sağlıklı

şekilde bakımının yapılmasına olanak sağlamaktadır. 1999-2002 yılında gerçekleştirilen Uluslararası Bakım Konferansında sunulan bağımsız araştırmalar sonucunda kestirimci bakım uygulamasının bakım maliyetlerinde 15-30% azalma, kesinti süresinde 20-40% azalma, üretimde 15-25% artış sağladığını göstermiştir. Kestirimci bakım ekipmanlardaki sorunları ortadan kaldıramaz ve sistemin bozulmasını engelleyemez. Periyodik bakımı tamamen ortadan kaldıramaz. Verisi olmayan ya da verisi alınamamış bölümler hakkında bilgi edinemez. Kestirimci bakımın avantajları aşağıdaki gibi sıralanabilir:

- Meydana gelebilecek arızaları ve bu arızaların oluşturabileceği ikincil hasar risklerini azaltır.
- Ekipmanları meydana getiren mekanik parçaların ömürleri hakkında bilgi edinmemizi ve ortaya çıkabilecek sorunlara karşı zamanında uyarıda bulunabilir.
- Periyodik bakım faaliyetlerinin sayısını azaltır.
- Ekipman performansını ve ömrünü artırır.
- Tesiste beklenmedik aksamaların, duraksamaların süresini azaltır.
- Bakım maliyetini parça ve işçilik olarak azaltır.
- Gereksiz parça sökümü, bakımını engeller.
- Ekipmanların ömür süresince istenilen koşullarda çalışma olasılığını artırır.

Kestirimci bakım üç aşamanın birleşimi ile oluşturulabilir:

1. **Gözetim:** Sorunları tespit etmek için ekipmanların izlenmesidir. Ekipmanlardan verilerin toplanması aşamasıdır.
2. **Teşhis:** Ekipmanın gerçek zamanlı olarak incelenmesi ile elde edilen verilerin değerlendirilmesiyle birlikte oluşabilecek sorunları önlemek ve düzeltmek için bir uygulama planı hazırlamaktır.
3. **Çözüm:** Sorunu önlemek ve düzeltmek için gerekli uygulamaların gerçekleştirilmesidir.

Her üç aşamada da tutarlı ve doğru veri toplamak eylemlerin doğru ve yerinde uygulanması için önemlidir. Ekipmanların durumunu değerlendirmek, verileri elde etmek için test teknikleri, görsel incelemeler ve performans verileri kullanılır. Elde edilen veriler ekipmanların durumu hakkında bilgi vermesi ve arıza meydana gelmeden önce fikir sahibi olunabilmesi için farklı analiz yöntemleri kullanılır [Gulati, 2009], [Palmer, 2013], [Campbell, 2015].

Bu analiz yöntemlerinden bazıları aşağıdaki gibidir:

1. **Trend analizi:** Bu yöntem bir tesiste bulunan ekipmanların işini yerine getiremeyeceği belirgin bir hal alıp almadığını incelemek için verileri inceler. Elde edilen veriler daha önce sağlıklı çalışma durumuna göre veya elde bulunan optimal hal çalışma durumu verileriyle karşılaştırılarak verilerdeki değişikliğin değerlendirildiği analiz türüdür.
2. **Biçim tanıma analizi:** Bir tesisteki ekipmanlar birbiriyle ilişkili olarak çalışmaktadır. Bir ekipmandan elde edilen veriler ışında o ekipmanın tetiklediği başka bir parçada meydana gelebilecek hasarların değerlendirildiği analiz kısmıdır. Birbiriyle ilişkili olarak çalışan parçalar arasında nedensellik ilişkilerini tespit etmek için verileri inceler.
3. **Korelasyon analizi:** Farklı analistlerden elde edilen veriler, veri elde etmek için kullanılan teknolojilerden ve farklı kaynaklardan elde edilen verileri karşılaştırır.
4. **Limitlere ve aralıklara karşı testler:** Ekipmanların çalışma koşulları belirlenir ve belirli limitler tanımlanır. Ekipmanların çalışabileceği çalışma sıcaklığı, çalışma basıncı, çalışma süresi gibi kısıtlayıcı limitler belirlenir ve çalışma durumunda bu limitlerin geçilip geçilmediğinin kontrol edilir [Gulati, 2009].

### 1.3. Arıza Tahmini

Sistemlerde meydana gelebilecek arızayı tahmin etmeye çalışmak ve bunu başarılı bir şekilde tahmin edebilmek için çeşitli yöntemler kullanılmaktadır. Sistem arızaları meydana gelmeden engellemek, ekipmanların bozulmalarını veya plansız durmalarını önlemek bakım stratejilerinin önemli hedeflerinden birisidir. Tahmine dayalı bakım yöntemi, sistemlerde meydana gelebilecek plansız duraksamaların önüne geçerek planlı

bir bakımın oluşabilecek arızaları doğru tahmin edilmesi ile kullanılabilirliği olan bir yöntemdir [Kaynak, 2022], [Leukel, 2021]. Kısa özetlemek gerekirse arıza tahmini, sistemlerde meydana gelebilecek bir arızanın varlığını veya yokluğunu tahmin etmek için önceki verilerin, mevcut verilerin analizi edildiği bir veri madenciliği olarak özetlenebilir [Dashti, 2021].

Arıza tahmininde kullanılacak çalışma verilerinin sağlıklı bir şekilde toplanması aşağıdaki sebeplerden dolayı zordur:

1. Makineler çoğunlukla uzun yıllar boyunca çalıştığından geniş bir bozulma sürecini kapsar. Bu uzun süreç içinde oluşacak tüm verilerin kayıt altına alınması zordur.
2. Arızanın gerçekleşmesini bekleyip veri alımını bozulma gerçekleşince tamamlamak hem kazalara yol açabilir hem de maliyet olarak yüksek olması sebebi ile arızalanma izin verilmeden veri alımı durdurulur.
3. Uçak motorları vb. makinelerin verileri dış ortamdaki koşullardan yüksek miktarda etkilendiği için veri yüksek miktarda gürültü içerir.
4. Bozulmaya kadar veri alımı yapabilen ticari ya da askeri kurumlar verilerini belli sebeplerden dolayı kısıtlı şekilde paylaşır [Lei, 2018].

#### **1.4. Kalan Faydalı Ömür**

Kalan faydalı ömür tahmini, kestirimci bakımın kullanıldığı önemli bir yöntemdir. Kalan faydalı ömür tahmini ekipmanın sağlıklı bir şekilde ne kadar daha süre çalışabileceği hakkında bilgi sahibi olmamıza yardımcı olur. Bu yöntemle beraber sistemdeki kesintiler azalır, bakım maliyeti azalır ve ekipmanın arızalanması sonucu ortaya çıkabilecek olası olumsuzluklardan kurtulmasına olanak sağlar. Kalan faydalı ömrünün tahmin edilmesi için yapay zekâ, çeşitli yazılımlar, sensörler ve makine öğrenmesi uygulamaları kullanılır. Makine öğrenmesindeki gelişmeler ekipmanlar hakkında daha fazla ve doğru veri toplanmasına olanak sağlamıştır. Böylece ekipmanlar hakkında ömür tahminini daha doğru yapılmasına yardımcı olmuştur. Makine öğrenmesi uygulamaları kullanarak model karmaşıklığı azaltılabilir [Lui, 2021].

Kalan faydalı ömür tahmini üç farklı yöntem kullanılarak gerçekleştirilir. Fizik tabanlı, veri tabanlı ve hibrit yaklaşım olarak üç farklı yaklaşım kullanılarak kalan ömür tahmini yapılabilir. Fizik tabanlı model oluşturularak kalan faydalı ömrü tahmin etmek mümkün olabilir fakat karmaşık sistemlere uygulamak oldukça maliyetli bir yöntemdir. Veri tabanlı yaklaşım karmaşık sistemlerde geçmiş verileri kullanarak, karşılaştırma yaparak analiz eder ve kalan faydalı ömrü tahmin eder. Bu yaklaşım fizik tabanlı yaklaşıma göre daha hızlı ve ucuz bir tahmin yöntemidir [Kaynak, 2022].

Kalan faydalı ömür tahmini yapılarak sistem bakımı planlanabilir, çalışma performansı ve verimi optimize edilebilir. Tahminin doğru bir şekilde yapılabilmesi için farklı yöntemler olduğu yukarıda belirtilmiştir. Bu yöntemlerin sağlıklı bir tahminde bulunabilmesi mevcut veri türlerine bağlıdır. Bu veriler ömür boyu veriler, arızaya kadar çalışma süreci ve arıza durumunda bilinen eşik değeri verileridir [Baru, 2023].

Kalan faydalı ömür (RUL) tahmininde en önemli faktörlerden biri motorun çalışma verilerinde standart aralığının bilinerek motor bozulmasının başladığı sınır değerinin belirlenerek verilerin gözlemlenmesidir. Çünkü tüm motor üniteleri ve bu ünitelerle bağlantılı bileşenler başlangıçta stabil düzende bir süre çalıştıktan sonra arızaya ulaşırlar. Yani arızalar uzun bir zaman serisinde çıkar. [Asif, 2022]

#### **1.4.1. Fiziğe Dayalı RUL Tahmini**

Fizik tabanlı RUL tahmini, teorik modellerin oluşturulabildiği durumlarda kullanılabilir. Oluşturulan modeller çalışma süreci takip edilen ekipmanlar için özel olarak tasarlanmalı ve elde edilen veriler doğru şekilde analiz edilmelidir. Farklı çalışma koşullarının değerlendirilmesinde oldukça kullanışlıdır. Sistem fiziği, çatlak oluşumu, aşınma, korozyon gibi arıza çeşitlerinin tanımlanmasında etkili bir yöntemdir. Fiziksel bir model elde edebilmek için fiziksel denklemler kullanılır. Oluşturulan modelin amacına uygun olacak şekilde parametreler belirlenir ve bu parametre verileri kullanılarak tahmin yapılır. Tasarlanan her sistem için RUL tahmini yapabilmek amacıyla yeni bir model ve algoritma oluşturulması gerekir. Bu nedenle fizik tabanlı RUL tahmin metodolojisinin kullanımı sınırlıdır [Ahmadzadeh, 2014], [Si, 2011], [Yan, 2021], [Zeng, 2020].

Literatürde farklı ekipmanların kalan faydalı ömür tahminini yapılması için fizik tabanlı birçok yöntem önerilmiştir [Lui, 2021], [Yan, 2021], [Zeng, 2020] [Al-Greer, 2023], [Downey, 2019].

Yan ve arkadaşları, ekipmanlarda yorulma çatlağından kaynaklanan ekipmanların RUL tahmini için iki aşamalı fizik tabanlı bir RUL modeli önermişlerdir. Önerilen modelin yüksek RUL tahmin doğruluğuna ulaştığı sonucuna varmışlardır [Yan, 2021].

Lui ve arkadaşları, lityum iyon pillerinin RUL tahmini için fizik tabanlı bir model yaklaşımı önermişlerdir. Fizik tabanlı modelde kullanılacak bozulma parametreleri yüksek hassasiyetli yük eğrilerinden tahmin etmişlerdir [Lui, 2021].

#### **1.4.2. Veri Tabanlı RUL Tahmini**

Veri tabanlı RUL tahmini, çalışma süreci boyunca durum izleme verileri, başlangıç verileri, çalışma verileri ve bozulma süreci verilerinin değişimlerine dayanmaktadır. Elde edilen bu veriler çeşitli algoritmalarla mantıksal bilgiye dönüştürülerek RUL tahmini yapılır. RUL tahminin doğruluğu veri sayısına ve verilerin kalitesiyle doğru orantılı olarak artmaktadır. Veri tabanlı metodoloji toplanan verileri girdi ve çıktı verileri olarak ayırmaktadır. Bu yöntem örüntü tanıma yöntemiyle elde edilen istatistiksel ve öğrenme tekniklerine dayanmaktadır. Doğrusal regresyon veya kalman filtreleri gibi geleneksel sayısal algoritmaları, makine öğrenimi ve veri madenciliğinde kullanılan algoritmaları kapsamaktadır. Yaygın olarak kullanılan veri tabanlı metodolojiler yapay sinir ağları (YSA), istatistiksel yaklaşım, bayesian yöntemleri, gizli markov modelleri (HMM), yarı gizli markov modelleri (HSMM), tehlike oranı (HR) olarak sınıflandırılabilir [Ahmadzadeh, 2014], [Si, 2011], [Petrooulos, 2022].

#### **1.4.3. Hibrit Tabanlı RUL Tahmini**

Karmaşık sistemlerde RUL tahmini için tek bir yöntemin kullanılması bazen yeterli kalmamaktadır. En az iki farklı metodolojinin beraber kullanılarak kalan faydalı ömür tahminin yapıldığı yöntemlere hibrit tabanlı RUL tahmin yöntemi denilmektedir. Veri elde etme, veri analizi ve modelleme için farklı prognostik yaklaşımları birleştiren, duruma dayalı bir tahmin yöntemi olarak kullanılmaktadır. Hesapların karmaşıklığını azaltır. Tek bir yöntem kullanılarak yapılan tahminlerde oluşan olumsuzlukları ikinci bir

yöntem kullanarak olumsuzlukları azaltmayı ve daha doğru bir RUL tahmini elde etmeyi amaçlamaktadır [Ahmadzadeh, 2014], [Si, 2011], [Petropoulos, 2022].

Liu ve arkadaşları uçak yardımcı güç ünitesinin kalan faydalı ömrünü tahmin edebilmek için yapay zekâ tabanlı bir model ile fizik tabanlı bir modelin birleştirilmesiyle hibrit bir RUL tahmin yöntemi önermişlerdir. Uçak güç ünitelerinde meydana gelen bozulmaların doğrusal olmadığı bu nedenle sadece veriye dayalı veya fizik tabanlı yöntemlerin yeterli olmayacağını savunmuşlardır. Daha doğru bir RUL tahmini için hibrit yaklaşımlı bir RUL tahmin modeli önermişlerdir [Liu, 2020].

Zraibi ve arkadaşları lityum iyon pillerin kalan faydalı ömürlerini tahmin edebilmek için evrişimsel sinir ağı (CNN), uzun kısa süreli bellek (LSTM) ve derin sinir ağlarının (DNN) birleşimi olan CNN-LSTM-DNN olarak isimlendirilen hibrit bir yaklaşım önermişlerdir. Önerilen sistemin doğrulunu ve üstünlüklerini çeşitli tahmin algoritmalarıyla karşılaştırmışlardır. Hibrit yaklaşımın tek bir yöntem kullanılan tahmin yöntemlerine kıyasla daha doğru tahmin sonuçları elde ettiği sonucuna varmışlardır [Zraibi, 2021].

Sun ve arkadaşları kesici takımların kalan faydalı ömürlerini tahmin edebilmek için fizik tabanlı ve veri tabanlı yöntemlerin avantajlarını birleştiren bir hibrit yaklaşımlı RUL tahin yöntemi önermişlerdir. Veri tabanlı yöntem kullanarak kuvvet, titreşim verilerini kullanarak ampirik mod ayrıştırması ve geri yayımlı sinir ağı tabanlı olarak kesici takımların aşınma durumları hakkında bilgiler edinmişlerdir. Fizik tabanlı yöntem kullanarak ise Wiener prosesine dayanan, kesici takımın RUL tahmini için bir kesici takımın bozulma durumunun modelini oluşturmuşlardır [Sun, 2018].

### 1.5. Literatür Taraması

Bu bölümde bakım yöntemleriyle ilgili olarak yapılmış son zamanlardaki çalışmaların incelenmesi yapılacaktır. Farklı yöntemlerin kullanılması değerlendirilmiş ve yapılan çalışmalar tez çalışması için referans değerleri içermektedir.

Wang ve arkadaşları yaptıkları çalışmada bozulma sürecindeki rulmanların kalan faydalı ömrünü tahmin edebilmek için zaman-frekans verilerinin değişimine bağlı olarak fizik destekli uzun kısa süreli bellek ağı önerilmektedir. Önerilen uzun kısa süreli bellek ağının gerçek fizik yasalarına uyması ve daha gerçekçi bir kalan faydalı ömür tahmini yapılması

için fizik destekli bir bellek ağı kullanıldığı vurgulanmaktadır. Önerilen sistem rulman bozulma aşamasını sağlıklı durum ve bozulmuş durum olarak ikiye bölerek rulman titreşim sinyalindeki gürültü model sonuçları çıkarılmıştır. Daha sonra Pearson korelasyon katsayısı, sağlamlık gibi fiziksel tutarlılığı sağlayacak dinamik ağırlıklar seçilmiştir. Yapılan çalışma sonucunda oluşturulan fizik destekli bellek ağı deneysel verilerle karşılaştırılmış ve tutarlı bir kalan faydalı ömür tahmini yapıldığı belirtilmiştir [Wang, 2024].

Xiang ve arkadaşları uçak motoru kalan faydalı ömrünün daha doğru ve sağlam şekilde tahmin edebilmek kütle korumalı uzun ve kısa süreli bellek ağı (MCLSTM) tabanlı bir çerçeve geliştirmişlerdir. MCLSTM seviye bölme birimi ve gizli katmandaki çok hücreli birimlerden oluşturulmuştur. Seviye bölme ünitesi ile farklı verilerin farklı eğilim bilgilerini temsil edebileceği böylece girdi verilerinin önem derecesinin belirlenmesi için seviye bölme ünitesi tasarlamışlardır. Mevcut giriş verileri önerilen yeni ünite yardımıyla yüksek, orta-yüksek, orta, orta-düşük ve düşük olmak üzere beş seviyeye bölmüşlerdir. Beş seviye, yaşam döngüsü bozulma eğilimindeki beş eğilime karşılık geldiğini belirtilmiştir. Elde edilen verilerin seviyelerine bağlı olarak çok hücreli birimlerde farklı güncelleme modları tasarlamışlardır. MCLSTM elde edilen veriler işlenerek uçak motorunun sağlık durumu hakkında bilgiler elde edilmiştir. Deneysel sonuçlar sonucundan önerilen metodolojinin mevcut kalan faydalı ömür tahmin yaklaşımlarından çok daha üstün olduğu sonucuna varmışlardır [Xiang, 2021].

Hu ve arkadaşları aero-turbofan uçak motorlarının kalan faydalı ömür tahmini için otomatik olarak genişletebilen basamaklı uzun-kısa süreli bellek (ACLSTM) modeli oluşturmuşlardır. ACLSTM modeli ampirik formülasyon optimizasyonu ile desteklenmiştir. Önerilen bu model alt modüllerin genişletilmiş basamaklama mekanizmasına sahiptir. Bu alt modüller yardımıyla tahmin hatasını en aza indirmek amaçlanmıştır. Çalışmada alt modül kademesinin artmasıyla tahmin hatalarının da azalma olacağı ayrıca belirtilmiştir. Uçak motorlarının karmaşık mekanik yapısı ve çalışma durumu nedeniyle LSTM ağının tahmin doğruluğunun gerçekliliğinin tek başına yeterli olmayacağını bu yüzden uçak motorlarının ömür boyu değişim yasalarını içeren ACLSTM tahmin modeli önerdiklerini belirtmişlerdir. Önerilen ACLSTM modeli önceki tahmin hatalarını sonraki modülün eğitim çıktıları olarak sürekli olarak ayarlamak için adım adım bağlanan bir fazla LSTM modülünün ağ yapısını benimsemektedir. Böylece

orijinal verilerin tahmin sürecini çıktı hatasına dönüştürerek tahmin hatasını etkili bir şekilde azaltacağını iddia etmişlerdir. Önerilen bu model Ulusal Havacılık ve Uzay Dairesi tarafından yayınlanan C-MAPSS veri setinin dört alt kümesine göre test etmişlerdir. Önerilen ACLSTM tahmin modelin ortalama karekök hatasını (RMSE) standart bir LSTM ağına kıyasla ortalama 95,44% oranında azalttığı gözlemlenmiştir [Hu, 2023].

Mitici ve arkadaşları turbofan motorunun kalan faydalı ömür tahmini yapabilmek için evrişimsel sinir ağlarını kullanarak olasılıksal bir RUL prognostikleri geliştirmişlerdir. Önerilen sistem geleneksel Zamana dayalı bakım stratejiyle kıyaslandığında maliyeti 53% 'lük bir düşme sağlanmıştır [Mitici, 2023].

Lei ve arkadaşları makinelerin kalan faydalı ömürlerini tahmin edebilmek için model tabanlı bir yöntem önermişlerdir. Önerilen yöntem gösterge yapısı ve RUL tahmini olarak iki modülden oluşmaktadır. İlk modül ağırlıklı minimum niceleme hatası olarak adlandırılan yeni bir sağlık göstergesini içermektedir. Bu yeni gösterge elde edilen verilerden ortak bilgileri içeren verileri birleştirir ve bu verileri makinenin arızalanma süreciyle ilişkilendirir. İkinci modül olasılıksal bir tahmin algoritması kullanarak model koşullarını başlatır ve ekipman ayırma tabanlı bir algoritma kullanarak RUL tahmin eder. Yazarlar önerdikleri bu iki modüllü RUL tahmin etme yöntemini döner elemanlı rulmanların bozulma testlerinde elde edilen titreşim sinyallerini kullanmışlardır. Önerilen yöntemin makinelerin RUL tahmininde etkili bir şekilde kullanılabileceği sonucuna varmışlardır [Lei, 2016].

Tian, durum izlemeye bağlı parçaların kalan faydalı ömür tahminini iyileştirmek için YSA tabanlı bir yöntem geliştirmiştir. YSA modülü girdi verisi olarak mevcut ve önceki denetim noktalarındaki yaş ve çoklu durum izleme ölçüm değerlerini, çıktı veri olarak ise ömür yüzdesini kullandığını belirtmiştir. Önerilen sistem pompa yataklarında toplanan gerçek titreşim izleme verileri kullanılarak doğrulamıştır. Önerdiği YSA yönteminin RUL tahmini elde etmede uygulanabileceğini belirtmiştir [Tian, 2012].

Ma ve arkadaşları dönen makinelerin kalan faydalı ömrünü doğru tahmin edebilmek için evrişim tabanlı uzun kısa süreli bellek (CLSTM) olarak adlandırdıkları yeni bir derin sinir ağı önermektedirler. Evrişim tabanlı sinir ağının, uzun kısa süreli bellek ağına bağlandığı literatürde çok sayısı da çalışma olduğunu vurgulamışlardır. Kendi önerdikleri sistemin

literatürde bulunanlardan farklı olarak hem girişten duruma hem de durumdan duruma geçiler üzerinde evrişimli işlem yürüttüğünü vurgulamışlardır. Önerilen sistem ile kodlama-tahmin mimarisi oluşturmuşlar ve RUL tahmini için derin öğrenme modeli oluşturmuşlardır. Rulmanlar arızalana kadar çalışma testleri yapılmış ve titreşim tepkileri toplanmıştır. Önerilen modül kullanılarak RUL tahmin edilmiş ve karşılaştırma olarak derin CNN'ler ve derin LSTM dahil olmak üzere diğer yöntemlerin performansı ortak veri kümesi kullanılarak değerlendirmişlerdir. Böylece CLSTM ağının karşılaştırmalar sonucu daha iyi tahmin doğruluğu ve hesaplama verimliliği elde etmişlerdir [Ma, 2020].

Costa ve arkadaşları uçak motorunun kalan faydalı ömrünü tahmin edebilmek için izleme verilerinin değerlendirildiği varyasyonel kodlamaya dayalı yeni bir yaklaşım önermişlerdir. Oluşturdukları model, tekrarlayan bir kodlayıcı ve bir regresyon modelidir. Kodlayıcı, girdi verilerini, uçak motorlarının bozulma oranını görsel olarak değerlendirebilen kendi kendini açıklayan bir harita oluşturmuştur. Bu çalışmada turbofan motorlarından alınan veriler kullanılmıştır. Kalan Faydalı Ömrü (RUL) tahmin yorumlarını, elde ettikleri verilerle desteklemişlerdir. Böylece yalnızca yoruma dayalı bir değerlendirme değil aynı zamanda bir prognostik doğruluk elde edilebileceğini vurgulamışlardır [Costa, 2022].

Li ve arkadaşları bilgi ve derin öğrenme modellerinin modellenmesiyle elde ettikleri modül ile uçak modüllerinin kalan faydalı ömrünü tahmin etmek için bir yöntem önermektedirler. Önerilen modül bilgi ve derin öğrenme modellerini birleştiren, bilgi güdümlü hibrit bir model (KGHM) önerilmiştir. Önerilen yaklaşım, sensör ilişkilerini, kümeleme için gömme vektörleri olarak dönüştürmüş ve akış şemaları olarak temsil edildiği belirtilmiştir. Bu kümeleme sonuçları daha sonra sensör veri düzenlemesine ve hibrit derin öğrenme modeli yapımında rehber olması için kullanılmışlardır. Yapılan çalışma sonucunda, önerilen yaklaşımının yaptıkları literatür çalışmasına göre 5,5% oranında tahmini iyileştirdiği sonucuna varmışlardır. Araştırmalarında tahmin sonuçları için bilgi ve derin öğrenme modellerinin birleştirilmesinin uygulanabilirliği ve yorumlanabilir olabileceği vurgulanmıştır [Li, 2023].

Nieto ve arkadaşları, hibrit parçacık sürü optimizasyonu (PSO) ve destek vektör makinesi (SVM) tabanlı yöntem kullanarak uçak motorlarının RUL tahmini için hibrit bir model önermişlerdir. Önerilen hibrit model, regresyon problemleri için destek vektör

makinelerini, parçacık sürü optimizasyonu tekniği ile birleştirmiştir. Bu yöntemin en önemli avantajlarından birisinin, motorun önceki çalışma durumları hakkında bilgi gerektirmemesi olduğunu vurgulanmıştır. Yapılan çalışma sonucunda önerilen hibrit sistemin regresyon doğruluğu yaklaşık 95% olarak bulunmuştur [Nieto, 2015].

Liu ve arkadaşları, uçak motorunun RUL tahmin doğruluğunu geliştirmek amacıyla, kümelemeli geliştirilmiş çok aşamalı uzun kısa süreli bellek ağı (ILSTMC) olarak isimlendirdikleri yeni bir uçak motoru RUL tahmin modeli önermişlerdir. Önerilen bu modelle, kümeleme analizi ve LSTM modelinin avantajlarını bütünleştiren çok aşamalı bir RUL tahmin algoritması geliştirilmeye çalışılmışlardır. Yapılan deneysel çalışmalar sonucunda, önerilen yöntemin uçak motoru RUL tahmin hatasını önemli bir şekilde azalttığını gözlemlemişlerdir. Doğrulama için NASA veri seti benimsenmiştir [Liu, 2021].

Zhu ve arkadaşları rulmanların RUL tahmini için zaman frekans gösterimi (TFR) ve çok ölçekli evrişimli sinir ağı (MSCNN) yaklaşımlarını içeren yeni bir derin özellik öğrenme yöntemi geliştirmişlerdir. Zaman serisi bozulma verileri elde etmişler ve dalgalı dönüşümü kullanarak TFR verileri elde etmişlerdir. Elde edilen TFR verilerini derin öğrenme modellerinin girdileri olarak kullanmışlardır. Önerilen modülün etkinliğini deneysel verilerle doğrulamışlardır. Geleneksel veri odaklı ve farklı sinir ağ tabanlı yöntemlerle karşılaştırma sonucunda önerilen yöntemin tahmin doğruluğunda gelişmiş performans gösterdiğini belirtmişlerdir [Zhu, 2018]

Khelif ve arkadaşları, destek vektörü regresyonuna dayalı kalan faydalı ömür tahmini yapmak için bir model önerilmiştir. Önerilen modelin performansını değerlendirmek için turbofan veri seti kullanılmıştır. Yazarlar, bozulma zamanını veya bozulma eşiğini tahmin etmeye gerek duymadan ekipmanların kalan faydalı ömürlerini sensörler yardımıyla tahmin edebilen bir yöntem önerilmiştir. Sensör verileri ve sağlık göstergeleri arasındaki ilişki destek vektör regresyonu kullanılarak modellenmiştir. Bu model kullanılarak arıza meydana gelmeden önce bozulma sürecinde RUL anında tahmin edilebileceği vurgulanmıştır. Bu yöntem ile arızaya sebep verilmeden anında müdahale edilebileceğini, hesaplama süresini azalttığı ve kalan faydalı ömür tahmini doğruluğunu artırdığı sonucuna varmışlardır [Khelif, 2016].

Kang ve arkadaşları yapay sinir ağı modelleyerek üretim hatlarındaki ekipmanların kalan faydalı ömürlerini tahmin etmeye çalışmışlardır. Çalışmalarında ekipman arıza tahmini otomatik bir şekilde gerçekleştirebilecek yeni bir yapay sinir ağı modeli önermişlerdir. Önerilen sistem çok katmanlı algılayıcı sinir ağı (MLP) makine öğrenme algoritmasından oluşmaktadır. Önerdikleri yaklaşımı NASA turbofan motor veri kümelerindeki motorların RUL tahmini etmek için örnek olay araştırması olarak kullanmışlardır. Önerilen yaklaşımın RUL tahmininde etkili olduğunu ve tahmine dayalı bakım sonuçlarını iyileştirdiği sonucuna varmışlardır [Kang, 2021].

Mahamad ve arkadaşları rulman arızalarının doğru kalan faydalı ömür tahmini için yapay sinir ağı tabanlı bir modelleme önermişlerdir. Önerilen YSA modelinde, girdi verisi olarak mevcut ve önceki noktalardan elde edilen kök ortalama kare (RMS) ve basıklık Weibull tehlike oranının zaman ve uygun ölçümlerini kullanmışlardır Çıktı verisi olarak ise normalleştirilmiş yaşam yüzdesi ölçümleri kullanılmıştır. Önerdikleri model ile rulman arızasını tahmin etmede iyi performans elde ettiklerini belirtmişlerdir [Mahamad, 2021].


Ansari ve arkadaşları Elektrikli araçlarda bataryaların zamanında bakımı veya değiştirilmesi için bir RUL tahmini yapılması hedeflenmiştir. NASA pil veri seti kullanarak lityum iyon pillerin RUL tahmini için bir yapay sinir ağı tekniği önermişlerdir [Ansari, 2021].

Ahmadzadeh ve arkadaşları öğütme değirmenlerinin arızaya sebep vermeden bakımlarının yapılabilmesi için YSA tabanlı bir RUL tahmin yöntemi önermişlerdir. YSA yönteminin karmaşık sistemlerde kolayca uygulanabilme özelliğine vurgu yapmışlardır. YSA ekipmanın aşınmasını etkileyen süreç parametrelerine bağlı olarak oluşturulmuştur. Proses parametrelerini girdi, öğütme değirmen gömleklerinin yüksekliği ve kalan ömrünü ise çıktı olarak kullanmışlardır [Ahmadzadeh, 2021].

## **1.6. Gaz Türbinli Motorlar**

Bu bölümde gaz türbinli motorların çalışma prensibi, bölümleri, bakım süreçleri, havacılık sektöründe kullanımı hakkında bilgiler verilecektir.

Gaz türbinli motorlar, hava alığı, kompresör, yanma odası, türbin ve egzoz sistemi bölümlerinden oluşur. Motorun yapısı Şekil 1’de verilmiştir. Hava alığı havanın düzgün bir şekilde kompresöre iletilmesini sağlayan bölümdür. Motora giren havanın hızını ve basıncını kompresöre uygun aralıklara getirerek motorda daha verimli bir yanma oluşmasını sağlar. Bu yüzden hava alığı tasarımı motor verimi için oldukça önemli bir husustur. Gaz türbinli motorlarda kompresör, hava alığından gelen havanın yanma odasına ulaşmadan önce basıncını artırılması için kullanılır. Basıncı artırılan hava küçülür ve yanma odasında elde edilecek hava-yakıt karışımı daha optimal hale gelmiş olur. Kompresör dönen rotor ve sabit stator olmak üzere iki bölümden oluşur. Her bir rotor-stator ikilisi kademe olarak isimlendirilir. Rotor-stator kademesi yüksek performans ve yüksek sıkıştırma oranı elde etmek için çok kademeli olarak tasarlanır. Kompresörler güç kaybını azaltmak için iki aşamalı olarak tasarlanmaktadır. Gaz türbinlerinde eksenel ve radyal olmak üzere iki çeşit kompresör kullanılmaktadır. Havacılık sektöründe yüksek verim ve yüksek sıkıştırma özelliğinden dolayı gaz türbinli motorlarda eksenel kompresörler daha yaygın olarak kullanılmaktadır. Yanma odası, yakıt-hava karışımının yakıldığı bölümdür. Yanma sonucu elde edilen ısının sabit bir sıcaklıkta türbinlere iletilmesi için tasarlanmıştır. Kompresör yardımıyla sıkıştırılan hava yanma odasına iletilir ve burada yakıt ile karıştırılarak yanma meydana gelir. Yanma sonucu elde edilen enerji ile türbinler döndürülmektedir. Yanma yüksek sıcaklıklarda gerçekleştiği için yanma odası tasarımı yapılırken bu sıcaklığa dayanabilecek ve yanma odası içerisinde basınç kayıplarının minimum değerlerde tutulması dikkate alınarak tasarlanmalıdır. Türbin, yanma sonucu genişleyen gazdaki kinetik enerjiyi alır ve kompresörü ve diğer ekipmanları tahrik etmek için gerekli olan mil gücüne çevirir. Türbinlerde çark rotorları ve sabit kanatlı statorlar bulunur. Statorlar türbinlerde lüle görevi görürken çark rotorları kinetik enerjiyi mekanik mil enerjisine dönüştürürler. Egzoz sistemi, yanma sonucu oluşan atık gazların dışarı atıldığı sistemdir. Türbinden çıkan yanmış gaz nozul denilen bölümden dışarı atılır ve bir etki oluşur. Bu etki motorlara itiş gücü sağlamaktadır [Turan, 2009], [Gökdoğan, 2010].



Şekil 1. Gaz Türbinli Motor Kısımları [Eren, 2023]

Gaz türbinli motorlarının çalışma prensibi şu şekildedir; havayı emme, sıkıştırma, yanma ve egzoz dan oluşmaktadır. Emilen hava kompresörde sıkıştırılır, sıkışmış havanın basıncı artar ve yanma odasına iletilir. Yanma odasında yakıt ile karıştırılarak yanma meydana getirilir. Yanma sonucu yanmış yakıt-hava karışımı türbinlerden geçerken enerjisini türbine aktarır ve genişler. Son olarak yanmış yakıt-gaz karışımı egzozdan dışarı atılır. Bu çalışma prensibi termodinamikte brayton çevrimi olarak geçmektedir. Temel olarak gaz türbinleri dört çeşittir: Turbojet, turbofan, turboprop ve turboşarft. Havacılık sektöründe hız ve manevra ihtiyaçlarından dolayı savaş uçakları turbojet motorlar kullanır. Yolcu uçakları ise hız ve daha az yakıt tüketimi açısından turbofan motorlar kullanılmaktadır. Turbofan motorlar türbin ve fan kelimelerinin birleşmesinden meydana gelmektedir. Turbofan motorlarını turbojet motorlarından ayıran özelliği motorun ön kısmında havanın debisini artıran ve böylece motorun itme gücünü artıran ek bir fan bulunmaktadır. Fan motor içerisine daha fazla havanın girmesini sağlamaktadır. Böylece yanma odasına daha fazla hava girişi sağlanarak verim artırılmaktadır [Kerrebrock, 1992].

#### 1.6.1. Turbofan Motor Parametreleri

Turbofan motorlarının parametreleri önem seviyesi ve uçuş güvenliğine etkisi bakımından birincil (primary) ve ikincil (secondary) olarak iki gruba ayrılmaktadır [Çolak, 2016]. Birincil motor parametreleri her uçuş öncesi kontrol edilmelidir. İkincil

motor parametreleri uçuş boyunca kontrol edilmelidir. Turbofan motorlarda bakım planlaması yapılırken motor parametreleri dikkate alınmalıdır.

#### 1.6.1.1. Birincil Motor Parametreleri

- N1: Alçak basınç durumunda döner sistemlerin dönme hızı.
- N2: Yüksek basınç durumunda döner sistemlerin dönme hızı.
- EGT (Exhaust Gas Temperature): Motoru terk eden havanın sıcaklığı.
- Fuel Flow: Birim zamanda her bir motorun harcayacağı yakıt miktarı.
- EPR (Engine Pressure Ratio): Çıkış hava basıncı ile giriş hava basıncının oranı [Çolak, 2016].

#### 1.6.1.2. İkincil Motor Parametreleri

- FUSED: Motor start aldığı andan itibaren uçuş boyunca tükettiği yakıt miktarını gösterir.
- OIL: Motorun hidrolik aksanlarında dolanan hidrolik yağ miktarını gösterir.
- PSI: Hidrolik yağın basıncını gösterir.
- °C: Hidrolik yağ sıcaklığını gösterir.
- VIB: Alçak ve Düşük basınç sistemlerinde meydana gelen titreşim miktarını gösterir.
- NAC: Motordan çıkan havanın sıcaklığını gösterir [Çolak, 2016].

#### 1.6.2. Arıza Sebepleri

Turbofan motorlar karmaşık makinelerdir ve birçok bileşenin etkileşimde olduğu bir sistemdir. Bu motorlarda uzun süreli çalışma, yoğun titreşim ya da yüksek sıcaklık gibi durumlardan kaynaklı aşınma ve yıpranmalar oluşur. Bu yıpranmalar ilgili olduğu bileşenleri etkileyerek onların da performansında düşüşe sebep olur.

Motorlarda aşırı ısınma ve basınç, iç yapıların deforme olmasına çatlamalara ve erozyona yol açarak ciddi arızalara yol açabilir. Kalitesiz yakıt kullanımı motorun etkinliğini etkileyerek motor performansını olumsuz etkiler ve aşınma oluşturur. Motorun dış gövdesinde meydana gelen hasarlar, hava akışını etkileyerek verimliliği azaltır. Motor içine giren yabancı cisimler tıkanmalara yol açabilir ve ciddi problemler oluşturabilir. Motorun sağlıklı şekilde çalışmasını sağlayan kontrol sistemlerinde oluşan arızalar motorun yakıt ve hava karışımını düzenlemekte zorlayarak performans kaybına yol açabilir. Çalışan motor ve bileşenlerinin dış çevredeki kir ve tozdan etkilenerek havalandırma bölümleri, parçaların bıçakları aşınır. Motorlarda yangınlar kompresör, türbin ya da yanma odasının yanıcı madde ile karşılaşması sonucu oluşur. [Kurt, 2018]

## 2. BÖLÜM

### YÖNTEM VE MATERYAL

Bu bölümde ilk olarak çalışmada kullandığımız veri setinin özellikleri açıklanmıştır. Ardından veri ön işleme, özellik seçimi ve kurulacak modeller hakkında bilgi verilmiştir.

#### 2.1. Veri Seti

Çalışmamızda kullandığımız turbofan motorlar için veri seti, motorun durumunu kontrol etmek için kullanılan farklı sensörlerden elde edilen ve NASA C-MAPSS simülatörüyle oluşturulan bir veri setidir. Uçuş şartları deniz seviyesinden 35K ft'ye yükselişi ve deniz seviyesine geri inişi şeklindedir. Arıza, belirli bir zaman periyodunda meydana gelip, geri kalan uçuş zamanı boyunca da devam ederek motorun çalışma şartlarını etkilemiştir [Teubert, 2023].

FD001, FD002, FD003, FD004 olmak üzere dört alt kümeden oluşan veri setinden çalışmamızda FD001 alt kümesini kullanacağız. FD001 alt kümesi 26 öznitelik bilgisine sahip olup, bunlardan 3 tanesi operasyonel ayar 21'i ise sensör verisidir. Eğitim seti 100 motor ve 1 arıza modu olmak üzere 20631 örnek sayısından oluşmaktadır. Test seti ise 26 öznitelik ve 13096 örnek sayısından oluşmaktadır. Veri seti içinde test seti için RUL değerleri de verilmiştir, 100 örnek sayısından oluşmaktadır. Eğitim setini modeli eğitmek için kullanıp, kurulan modeli değerlendirmek için ise test veri setini kullanacağız. Öznitelikler ile ilgili bilgiler aşağıdaki gibidir:

Unit number (unit\_nr): Motor ünitesi, 1-100 aralığında değer alır, nümerik

Time, in cycles (time\_cycles): Motor ünitesinin uçuş sayısı, 1-362 aralığında değer alır, nümerik

Operational setting 1 (setting\_1): Çalıştığı koşul 1, irtifa -0.009-0.009 ft aralığında değer alır, nümerik

Operational setting 2 (setting\_2): Çalıştığı koşul 2, mach sayısı, -0.001-0.001 M aralığında değer alır, nümerik

Operational setting 3 (setting\_3): Çalıştığı koşul 3, deniz seviyesine göre sıcaklık, 100 °F değerini alır, nümerik

Sensor measurement 1 (s\_1): 1.sensör için ölçümler, fan girişindeki toplam sıcaklık, 518,67 °R değerini alır, nümerik

Sensor measurement 2 (s\_2): 2.sensör için ölçümler, LPC çıkışındaki toplam sıcaklık, 641.21-644,53 °R aralığında değer alır, nümerik

Sensor measurement 3 (s\_3): 3.sensör için ölçümler, HPC çıkışındaki toplam sıcaklık, 1571.04-1616,91 °R aralığında değer alır, nümerik

Sensor measurement 4 (s\_4): 4.sensör için ölçümler, LPT çıkışındaki toplam sıcaklık, 1382.25-1441,49 °R aralığında değer alır, nümerik

Sensor measurement 5 (s\_5): 5.sensör için ölçümler, fan girişindeki basınç, 14.62 psia değerini alır, nümerik

Sensor measurement 6 (s\_6): 6.sensör için ölçümler, baypas kanalındaki toplam basınç, 21.60-21.61 psia aralığında değer alır, nümerik

Sensor measurement 7 (s\_7): 7.sensör için ölçümler, HPC çıkışındaki toplam basınç, 549.85-556.06 psia aralığında değer alır, nümerik

Sensor measurement 8 (s\_8): 8.sensör için ölçümler, fiziksel fan hızı, 2387.9-2388.56 rpm aralığında değer alır, nümerik

Sensor measurement 9 (s\_9): 9.sensör için ölçümler, fiziksel çekirdek hızı, 9021.73-9244.59 rpm aralığında değer alır, nümerik

Sensor measurement 10 (s\_10): 10.sensör için ölçümler, motor basınç oran, 10959 değerini alır, nümerik

Sensor measurement 11 (s\_11): 11.sensör için ölçümler, HPC çıkışındaki statik basınç, 46.85-48.53 psia aralığında değer alır, nümerik

Sensor measurement 12 (s\_12): 12.sensör için ölçümler, yakıt akışının Ps30'a oranı, 518.69-523.38 pps/psi aralığında değer alır, nümerik

Sensor measurement 13 (s\_13): 13.sensör için ölçümler, düzeltilmiş fan hızı, 2387.88-2388.56 rpm aralığında değer alır, nümerik

Sensor measurement 14 (s\_14): 14.sensör için ölçümler, düzeltilmiş çekirdek hızı, 8099.94-8293.72 rpm aralığında değer alır, nümerik

Sensor measurement 15 (s\_15): 15.sensör için ölçümler, baypas oranı, 83.249-85.848 aralığında değer alır, nümerik

Sensor measurement 16 (s\_16): 16.sensör için ölçümler, yakıcı yakıt-hava oranı, 0,03 değerini alır, nümerik

Sensor measurement 17 (s\_17): 17.sensör için ölçümler, akış entalpisi, 388-400 aralığında değer alır, nümerik

Sensor measurement 18 (s\_18): 18.sensör için ölçümler, istenilen fan hızı, 2388 rpm değerini alır, nümerik

Sensor measurement 19 (s\_19): 19.sensör için ölçümler, istenilen düzeltilmiş fan hızı, 100 rpm değerini alır, nümerik

Sensor measurement 20 (s\_20): 20.sensör için ölçümler, HPT soğutma sıvısı akışı, 38.14-39.43 lbm/s değerini alır, nümerik

Sensor measurement 21 (s\_21): 21.sensör için ölçümler, LPT soğutma sıvısı akışı, 228.942-236.184 lbm/s aralığında değer alır, nümerik

RUL (sınıf): Motorun kalan ömrü

Parantez içinde belirtilen kısaltmalar kodlama ortamında kullanılmak üzere oluşturulmuştur.

## 2.2. Veri Ön İşleme

Büyük veriler çoğunlukla eksik, yanlış ve gürültülü veriler içermektedir. Verilerdeki gürültü oranı arttıkça veri üzerinde analiz yapmakta zorlaşır, elde edilecek sonuçların güvenilirliği de azalacaktır. Büyük verilerde öznitelik sayısının çok olması da verinin analizinde hem sonucun güvenilirliğini etkileyen noktalardan biridir hem de süreci yavaşlatmaktadır. Veride istenilen sonuca katkısı olmayan özniteliklerin varlığı kurulan modeli ve sonuçları etkilemektedir. Bu nedenle veri madenciliğinde analizin güvenilirliğinin yüksek olması için yapılması gereken en önemli işlem verinin ön işleminden geçirilmesidir. Veri ön işleme şu nedenlerle uygulanır:

1. Veriye uygulanacak analiz türünün veriden kaynaklı uygulanamaması
2. Verilerin anlamlı hale getirilmesi ve veri yapılarının anlaşılması
3. Veriden daha anlamlı bilginin çıkarılması [Oğuzlar,2003].

Çalışmada kullanılacak eğitim ve test veri setlerinde boş ya da alakasız veriler bulunmamaktadır. Eğitim veri setinde her motora ait uçuş döngüsü time\_cycles özniteliğinde tutulmaktadır. Her motorun geriye kalan faydalı ömür tahmini motor bozuluncaya kadar her döngüde birer azalarak devam edeceğinden dolayı eğitim setine etiket sütunu olarak RUL sütunu eklenmiştir. Eğitim verisine eklenen RUL sütunu Şekil 2’de verilmiştir.

|   | s_1    | s_2    | s_3     | s_4     | s_5   | s_6   | s_7    | s_8     | s_9     | s_10 | ... | s_13    | s_14    | s_15   | s_16 | s_17 | s_18 | s_19  | s_20  | s_21    | RUL |
|---|--------|--------|---------|---------|-------|-------|--------|---------|---------|------|-----|---------|---------|--------|------|------|------|-------|-------|---------|-----|
| 0 | 518.67 | 641.82 | 1589.70 | 1400.60 | 14.62 | 21.61 | 554.36 | 2388.06 | 9046.19 | 1.3  | ... | 2388.02 | 8138.62 | 8.4195 | 0.03 | 392  | 2388 | 100.0 | 39.06 | 23.4190 | 191 |
| 1 | 518.67 | 642.15 | 1591.82 | 1403.14 | 14.62 | 21.61 | 553.75 | 2388.04 | 9044.07 | 1.3  | ... | 2388.07 | 8131.49 | 8.4318 | 0.03 | 392  | 2388 | 100.0 | 39.00 | 23.4236 | 190 |
| 2 | 518.67 | 642.35 | 1587.99 | 1404.20 | 14.62 | 21.61 | 554.26 | 2388.08 | 9052.94 | 1.3  | ... | 2388.03 | 8133.23 | 8.4178 | 0.03 | 390  | 2388 | 100.0 | 38.95 | 23.3442 | 189 |
| 3 | 518.67 | 642.35 | 1582.79 | 1401.87 | 14.62 | 21.61 | 554.45 | 2388.11 | 9049.48 | 1.3  | ... | 2388.08 | 8133.83 | 8.3682 | 0.03 | 392  | 2388 | 100.0 | 38.88 | 23.3739 | 188 |
| 4 | 518.67 | 642.37 | 1582.85 | 1406.22 | 14.62 | 21.61 | 554.00 | 2388.06 | 9055.15 | 1.3  | ... | 2388.04 | 8133.80 | 8.4294 | 0.03 | 393  | 2388 | 100.0 | 38.90 | 23.4044 | 187 |

5 rows x 22 columns

Şekil 2. Eğitim Setine RUL Değeri Sütunu Eklenmesi

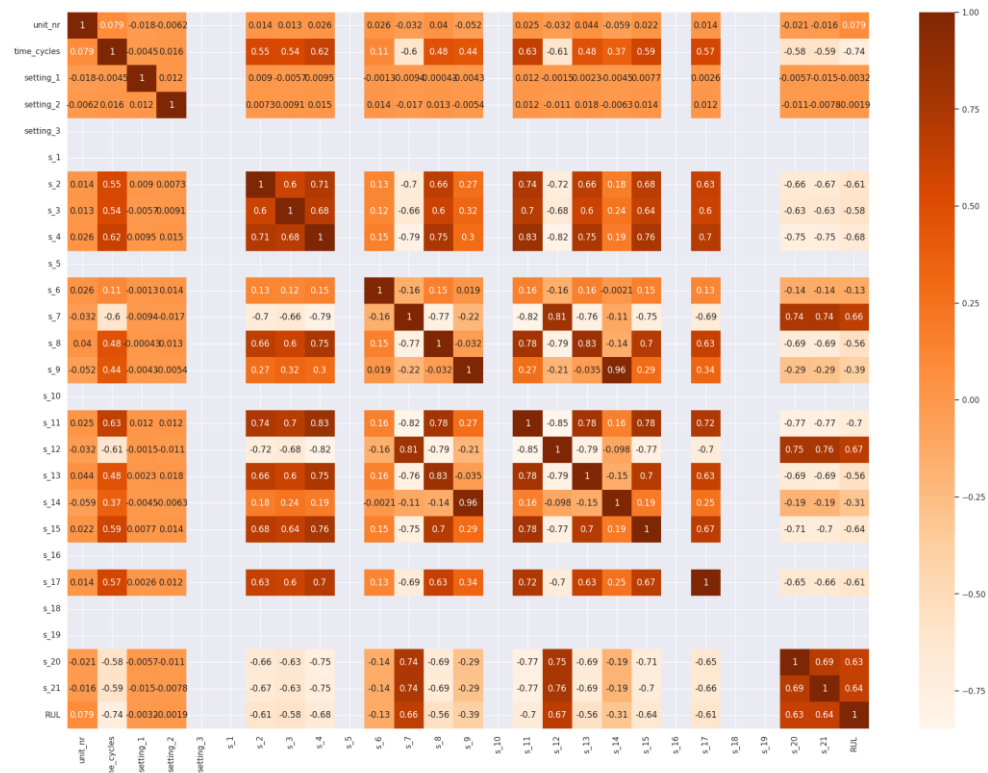
Aynı zamanda çalıştığımız ham veri seti örnek sayısının ve öznitelik sayısının fazla olduğu bir veri setidir. Veri kümesindeki öznitelikler farklı değer aralıklarında değerler almaktadırlar. Bir özniteliğin diğerine üstünlük sağlamaması için öznitelikleri aynı ortalama ve sapmaya sahip olacak şekilde standardizasyon işlemi yapılması gerekmektedir. Aksi taktir de büyük değere sahip olan özniteliklere doğru model oluşumu

kayacak ve bu durum model oluşumunu olumsuz etkileyecektir. Çalışmada z-skor yöntemi kullanılarak standartlaştırma yapılmıştır.

### 2.3. Özellik Seçimi

RUL değerinin tahmininde tahmini etkileyecek bir diğer konu ise özniteliklerin seçilmesidir.

Her öznitelik RUL değerinin tahmini üzerinde aynı derece de etkiye sahip olamaz. RUL ile zayıf bir ilişkiye sahip olan özniteliklerin model kurulurken de sürece dahil edilmesi model kurulurken zaman kaybına yol açar. Aynı zamanda diğer özniteliklerin etkisinin model üzerindeki etkisinin azalmasına ve modelin doğru kurulmasına engel olacaktır. Kurulacak modellerin vereceği çıktı kalitesini de önemli ölçüde etkileyecektir. Bu nedenle verideki özniteliklerin birbirleri ve RUL değerleri ile ilişkisinin incelenmesi önemlidir. Korelasyon bu ilişkinin incelenmesi için bir yöntemdir. Korelasyon iki değişken arasındaki ilişkiyi değişkenlerin -1 ya da +1'e yakınlığına göre ilişkilendirir. Çalışmamızda RUL tahmininde baskın olan özniteliklerde korelasyon değerleri hesaplanarak seçilecektir. Oluşturulan korelasyon ısı matrisi Şekil 3'te verilmiştir.



Şekil 3. Korelasyon Isı Matrisi

Setting\_3, s\_1, s\_5, s\_10, s\_16, s\_18, s\_19 özniteliklerinin korelasyonu sıfır çıkmıştır. Yani RUL tahmininde bu özniteliklerin hiçbir etkisi yoktur. Çalışmamızda 0,5 değerini sınır değeri olarak kabul ederek öznitelikleri ona göre seçeceğiz. Özniteliklerin korelasyonlarına bakıldığında Tablo 1’ deki öznitelikler seçilmiştir.

Tablo 1. Seçilmiş Öznitelikler

|             |           |
|-------------|-----------|
| time_cycles | -0.736241 |
| s_2         | -0.606484 |
| s_3         | -0.584520 |
| s_4         | -0.678948 |
| s_7         | 0.657223  |
| s_8         | -0.563968 |
| s_11        | -0.696228 |
| s_12        | 0.671983  |
| s_13        | -0.562569 |
| s_15        | -0.642667 |
| s_17        | -0.606154 |
| s_20        | 0.629428  |
| s_21        | 0.635662  |

RUL değerinin time\_cycles, s\_2, s\_3, s\_4, s\_8, s\_11, s\_13, s\_15, s\_17 ile negatif ancak güçlü bir ilişkisi, s\_7, s\_12, s\_20, s\_21 ile ise pozitif yönlü güçlü bir ilişkisi vardır. Korelasyonları yüksek çıkan bu özniteliklerden time\_cycles, öznitelik olmaktan çıkarılacaktır çünkü başlangıçta oluşturduğumuz RUL değerleri ile zaten doğrusal bir ilişki kurduğu için korelasyonunun yüksek çıkması beklenen bir durumdur. Hem de bu çalışmada sensör değerlerinin modeller üzerinde etkisini daha çok ortaya çıkarmak istediğimiz için time\_cycles baskınlık kurmaması ve aşırı öğrenmenin sonuçlarından kaçınmak için time\_cycles özniteliği seçilmemiştir. Modelin eğitileceği yeni öznitelikler bu bilgiler ışığında aşağıdaki gibidir: s\_2, s\_3, s\_4, s\_7, s\_8, s\_11, s\_12, s\_13, s\_15, s\_17, s\_20, s\_21.

## 2.4. Makine Öğrenim Yöntemleri

### 2.4.1. Doğrusal Regresyon (LR)

Doğrusal regresyon analizi, değişkenler arasındaki doğrusal ilişkinin modellenmesidir. Bir bağımlı bir bağımsız değişkenin bulunduğu doğrusal regresyona basit doğrusal regresyon denirken, bir bağımlı birden çok bağımsız değişkenin bulunduğu regresyona çoklu doğrusal regresyon ismi verilir. Bağımlı değişkenin değerini diğer değişkenler ile

tahmin ederek ilişki oluşturulur. Bağımlı değişkeni tahmin etme de diğer değişkenin ne kadar katkı sağladığını gösteren bir katsayı değeri ile denklem kurulur. Bu denklemin çözülmesi ile tahmin ve gerçek sonuçlar arasındaki farklar bulunur. Bu farklara hata denir. Bu hata farklarını minimuma indirmek için en küçük kareler yöntemi kullanılır [Girgin,2022].

#### **2.4.2. Destek Vektör Regresyonu (SVR)**

Denetimli öğrenme yöntemlerinden biri olan SVM veri kümesini önceden belirlenen sınıf sayısına ayırıp atama yapmak için en uygun düzlemi bulmayı amaç edinen bir makine öğrenim yöntemidir. Regresyon uygulamalarında kullanılmasından dolayı SVR model denilmektedir. Bu düzlemi en optimal şekilde bulmak asıl amaçtır. Oluşturulan düzlemlere en yakın destek vektörleri ile ayırım yapılır. Destek vektörü ile düzlem arasına denilen marjın maksimuma çıkarılması SVM modelinin amacıdır [Yıldırım, 2021], [Akay,2022].

#### **2.4.3. Karar Ağacı (DT)**

Karar vermede ağaç yapılarını kullanarak, iç düğümlerin nitelikleri, yaprakların sonucu, dalların ise karar kurallarını temsil ettiği bir makine öğrenim yöntemidir. Belli ölçütleri kullanarak en iyi niteliği seçerek modele başlar. Verileri daha küçük alt kümelerle parçalayarak hiçbir örnek ve nitelik kalmayana kadar ağaç yineleme sürecine devam eder ve süreci sonlandırır [Aydın, 2020].

#### **2.4.4. Rassal Orman (RF)**

Karar ağaçlarının farklı sonuçlarını beraber değerlendirme imkânı sunan rassal orman algoritması bir denetimli öğrenme algoritmasıdır. Seçilen veri örneklerinden ağaçlar oluşturulur ve tahminlemeler yapılır ve en iyi çözüm bulunur. Sınıflandırma yapılırken o verinin tüm ağaçlardaki durumu incelenir. Tahminleme için birçok ağaç kullanır bu nedenle aşırı uyumu azaltır, sonuç güvenilirliğini artırır [Cihan,2021].

#### **2.4.5. Yapay Sinir Ağları (ANN)**

Sinir ağları, sistemlerin yapısı ve sistemi meydana getiren parçalar hakkında bilgi sahibi veya varsayımlar olmadan karmaşık yapıya sahip ekipmanları araştırılması için bir olanak

sağlamaktadır. Bu yöntem sistemin çıktı ve girdi verilerini ilişkilendiren bir tanımlama ya da sistem ile ortak davranışlar sergileyen bir prototipin oluşturulmasını sağlamaktadır. Sinir ağları kullanılarak karmaşık sistemler modellenir ve RUL tahmini yapılabilir. Düzgün bir şekilde modellenmiş ANN yaklaşımı ile karmaşık sistemler kolay bir şekilde modellenebilir ve hızlı bir şekilde uygulanabilir. ANN yaklaşımı temelde iki farklı uygulaması mevcuttur. Uygulamalardan birisi verileri sınıflandırarak sistem arıza özelliklerini ve eğilimlerini tahmin edebilecek doğrusal olmayan fonksiyon modelleme diğeri ise sistem arıza dinamik süreçlerini modellemeyerek geri besleme bağlantısı oluşturmaktır [Ahmadzadeh, 2014], [Si, 2011].

#### 2.4.6. XGBoost

Sınıflandırma ve regresyon karar ağaçlarından oluşan XGBoost algoritması gradyan artırma algoritmasından geliştirilmiştir. Regresyon ağaçlarını oluşturarak güçlü öğrenme algoritması üretir. Aşırı öğrenmenin önüne geçmek için gama parametresi ile residual değeri ölçülür. Çalışma prensipleri gradyan artırma algoritması ile aynı olmasına rağmen performans olarak daha iyidir [Acar,2022].

#### 2.5. Performans Değerlendirme Ölçütleri

Modeli kurarken hem modelin hem de tahmin sonuçlarının güvenilir olmasındaki en önemli noktalardan biri verinin hazırlanması diğeri ise sonuçların doğru yorumlanmasıdır. RMSE, R2, ortalama mutlak hata (MAE), ortalama kare hata (MSE) gibi farklı performans değerlendirme ölçütleri vardır. Belirleme katsayısı (R2) doğruluğunun ölçüsüdür. R2 sonucu ne kadar büyük olursa model iyidir. MSE, RMSE ve MAE ise hatanın derecesidir. Bu ölçütler ne kadar düşük olursa model o kadar iyidir. Çalışmamızda RMSE ve R2 ölçütlerini değerlendirerek modelimizi yorumlayacağız.

RMSE değerinin formülü Denklem (1)'de, R2 formülü ise Denklem (2)'de gösterilmiştir [Özen, 2021]. Değerlendirme yapmak için tek bir performans ölçümünün yorumlanması yeterli değildir. Performanslar beraber değerlendirilmelidir [Gültepe,2019].

$$RMSE = \sqrt{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2 / N} \quad (1)$$

$$R2 = 1 - \frac{\sum (Y_t - \hat{Y}_t)^2}{\sum (Y_t - \bar{Y})^2} \quad (2)$$

$N$ : Gözlem sayısı.

$Y_t$  : Gerçek değer

$Y_{t_i}$ : Tahmin edilen değer.

$\tilde{Y}$ : Gerçek değerlerin ortalaması.

Verinin ön işlemden geçmesi ve öznitelikler seçildikten sonra kurulacak modeller hakkında bilgi verilmesi aşamasından sonra model sonuçlarını inceleme ve değerlendirme aşamasına geçilmiştir.




## 3. BÖLÜM


### BULGULAR

#### 3.1. Uygulama Sonuçları


RUL ile sensör değerleri arasındaki ilişkiyi gösteren grafikler Şekil 4'te verilmiştir.




a) Sensör 1 ve RUL arasındaki ilişki




b) Sensör 2 ve RUL arasındaki ilişki




c) Sensör 3 ve RUL arasındaki ilişki




d) Sensör 4 ve RUL arasındaki ilişki




e) Sensör 5 ve RUL arasındaki ilişki




f) Sensör 6 ve RUL arasındaki ilişki




g) Sensör 7 ve RUL arasındaki ilişki




ğ) Sensör 8 ve RUL arasındaki ilişki




h) Sensör 9 ve RUL arasındaki ilişki




ı) Sensör 10 ve RUL arasındaki ilişki




i) Sensör 11 ve RUL arasındaki ilişki




j) Sensör 12 ve RUL arasındaki ilişki




k) Sensör 13 ve RUL arasındaki ilişki




l) Sensör 14 ve RUL arasındaki ilişki




m) Sensör 15 ve RUL arasındaki ilişki




n) Sensör 16 ve RUL arasındaki ilişki




o) Sensör 17 ve RUL arasındaki ilişki




ö) Sensör 18 ve RUL arasındaki ilişki



p) Sensör 19 ve RUL arasındaki ilişki



r) Sensör 20 ve RUL arasındaki ilişki




s) Sensör 21 ve RUL arasındaki ilişki

Şekil 4. RUL ve Sensörler Arasındaki İlişkinin Grafikleri

1, 5, 10, 16, 18 ve 19 numaralı sensörlerin grafiği benzerdir, sensörler RUL tahmininde hiçbir yararlı bilgi içermemektedir. Sensör 2 yükselen bir trend göstermektedir, benzer bir davranış 3, 4, 8, 11, 13, 15 ve 17 numaralı sensörler için de görülebilir. Sensör 6'nın sensör okumaları zaman zaman aşağıya doğru tepe noktasına ulaşıyor ancak azalan RUL ile net bir ilişki yoktur. Sensör 7, 12, 20 ve 21'de bir düşüş eğilimi göstermektedir. Sensör 9 ile 14 benzer bir yapıya sahiptir.

RUL zaman serisi boyunca doğrusal olarak azalmaz. Çünkü makineler uzun zaman boyunca belli standart veri aralıklarında veri üreterek çalışır daha sonra ise belli sebeplerle bozulma başlar ancak yine de standart veri aralığından belli zamanlar içinde uzaklaşır ve daha sonra bozulurlar. Bu durum Şekil 5'teki grafikte de bellidir.



Şekil 5. Doğrusal RUL ve s\_12 Sensörü Arasındaki İlişki

Bu nedenle literatürde RUL değerlerini uçuş döngüsüne göre parçalı doğrusal azalan bir fonksiyonla ifade etmek önerilmiştir [Zeng, 2022]. RUL değerinin bu ifadesi kurulan modelin daha doğru bir tahminleme yapmasına olanak tanımaktadır. RUL değerlerini 125 değerinde düzeltme yaptıktan sonra oluşturulan modellerin sonuçlarını inceleyelim.


LR modeli için sonuçlar Tablo 2'deki gibidir.

Tablo 2. LR Modeli Sonuçları

| Model | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|-------|------------|----------|-----------|---------|
| LR    | 22.734     | 0.702    | 23.102    | 0.325   |

Lineer regresyon modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 22.734, R2 değeri ise 0.702, test seti için RMSE değeri 23.102, R2 değeri ise 0.325'tir. Alpha değeri Python kodlama dili kullanılarak GridSearch yöntemi ile optimize edilerek bulunmuştur. Şekil 6'da LR modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.

Mavi renk gerçek değerleri, kırmızı renk ise tahmin edilen değerleri göstermektedir. Şekil 6'daki grafikler incelendiğinde modelin tahmin gücünün yüksek olmadığı görülmektedir.



a)RUL ve tahmin edilen RUL grafiği (Eğitim) b)RUL ve tahmin edilen RUL grafiği(Test)


Şekil 6. LR Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

SVR modeli için sonuçlar Tablo 3'teki gibidir.

Tablo 3. SVR Modeli Sonuçları

| Model | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|-------|------------|----------|-----------|---------|
| SVR   | 21.429     | 0.736    | 19.927    | 0.498   |

Destek vektör regresyon modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 21.429, R2 değeri ise 0.736, test seti için RMSE değeri 19.927, R2 değeri ise 0.498'dir. C ve epsilon değerleri Python kodlama dili kullanılarak GridSearch yöntemi ile optimize edilmiştir. Lineer regresyon modeline göre daha iyi bir sonuç elde edilmiştir. Şekil 7'de SVR modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.



a)RUL ve tahmin edilen RUL grafiği(Eğitim) b)RUL ve tahmin edilen RUL grafiği (Test)


Şekil 7. SVR Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

DT modeli için sonuçlar Tablo 4'teki gibidir.

Tablo 4. DT Modeli Sonuçları

| Model | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|-------|------------|----------|-----------|---------|
| DT    | 20.754     | 0.752    | 22.214    | 0.376   |

Karar ağaçları modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 20.754, R2 değeri ise 0.752, test seti için RMSE değeri 22.214, R2 değeri ise 0.376'dır. Maksimum derinlik, minimum yaprak sayısı ve minimum örnek sayısı Python kodlama dilindeki optuna kütüphanesi ile optimize edilmiştir. Maksimum derinliğin 8, minimum yaprak sayısının ise 2, minimum örnek sayısının 15 olarak bulunmuştur. SVR ve lineer regresyon modelinden daha iyi bir tahminleme yapılmıştır. Şekil 8'de DT modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.



a) RUL ve tahmin edilen RUL grafiği (Eğitim) b) RUL ve tahmin edilen RUL grafiği (Test)


Şekil 8. DT Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

RF model için sonuçlar Tablo 5'teki gibidir.

Tablo 5. RF modeli Sonuçları

| Model | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|-------|------------|----------|-----------|---------|
| RF    | 20.401     | 0.760    | 20.994    | 0.442   |

Rastgele orman modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 20.401, R2 değeri ise 0.760, test seti için RMSE değeri 20.994 ve R2 değeri ise 0.442’dir. Maksimum derinlik, minimum yaprak sayısı, minimum örnek sayısı ve karar ağacı sayısı Python kodlama dilindeki optuna kütüphanesi ile optimize edilmiştir. Maksimum derinlik 7, minimum yaprak sayısı 10 ve minimum örnek sayısı 4 olarak bulunmuştur. LR, SVR ve DT modeline göre daha iyi bir tahminleme yapılmıştır. Şekil 9’da RF modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.



a)RUL ve tahmin edilen RUL grafiği(Eğitim) b)RUL ve tahmin edilen RUL grafiği (Test)


Şekil 9. RF Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

ANN model için sonuçlar Tablo 6’daki gibidir.

Tablo 6. ANN Modeli Sonuçları

| Model | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|-------|------------|----------|-----------|---------|
| ANN   | 19.544     | 0.780    | 20.290    | 0.479   |

Yapay sinir ağları modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 19.544, R2 değeri 0.780, test seti için RMSE değeri 20.290, R2 değeri ise 0.479’dur. Katman ve nöron sayıları Keras Tensorflow ile optimize edilmiştir. LR, SVR, DT ve RF modelinden daha iyi bir tahminleme yapılmıştır. Şekil 10’da ANN modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.



a) RUL ve tahmin edilen RUL grafiği (Eğitim) b) RUL ve tahmin edilen RUL grafiği (Test)


Şekil 10. ANN Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

XGBoost modeli için sonuçlar Tablo 7'deki gibidir.

Tablo 7. XGBoost Modeli Sonuçları

| Model   | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|---------|------------|----------|-----------|---------|
| XGBoost | 19.656     | 0.778    | 20.369    | 0.475   |

XGBoost modelinin sonuçlarını incelediğimizde eğitim seti için RMSE değeri 19.656, R2 değeri 0.778, test seti için RMSE değeri 20.369, R2 değeri ise 0.475'tir. Parametreler Python kodlama dilindeki optuna kütüphanesi optimize edilmiştir. LR, SVR, DT ve RF modeline göre daha iyi bir tahminleme yapılmıştır. Şekil 11'de XGBoost modeline göre eğitim seti ve test setleri için gerçek RUL ve tahmin edilen RUL değerlerinin grafikleri verilmiştir.



a) RUL ve tahmin edilen RUL grafiği (Eğitim) b) RUL ve tahmin edilen RUL grafiği (Test)

Şekil 11. XGBoost Modeli Gerçek RUL ile Eğitim ve Test Veri Setleri İçin Tahmin Edilen RUL Değerleri Arasındaki Grafik

Oluşturulan makine öğrenim yöntemlerine ait tüm modellerin sonuçları Tablo 8'deki gibidir.

Tablo 8. Tüm Modellerin Sonuçları

| MODEL   | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|---------|------------|----------|-----------|---------|
| LR      | 22.734     | 0.702    | 23.102    | 0.325   |
| SVR     | 21.429     | 0.736    | 19.927    | 0.498   |
| DT      | 20.754     | 0.752    | 22.214    | 0.376   |
| RF      | 20.401     | 0.760    | 20.994    | 0.442   |
| ANN     | 19.544     | 0.780    | 20.290    | 0.479   |
| XGBoost | 19.656     | 0.778    | 20.369    | 0.475   |

RMSE ve R2 değerleri incelendiğinde RMSE değerinin 0'a, R2 değerinin ise 1'e yakın olması beklenir. Bu bilgiler ışığında en iyi sonuç ANN modelinde gözlenmiştir. R2 ve RMSE değerleri tek başına değerlendirilmemiştir çünkü tek başına R2 değerini değerlendirmek veriler doğrusal ilişki içermiyorsa yanıltıcı olabilir. ANN modeli veri setine en uygun makine öğrenim yöntemi olarak seçilmiştir. ANN modelinin test veri seti üzerindeki sonucu RMSE değeri 20.290, R2 değeri ise 0.479'dur.

Eğer RUL değerinde 120 değerinde düzeltme işlemi yapıлып, parametreler bu değere göre ayarlanıp modeller kurulursa sonuçlar Tablo 9'daki gibi olur.

Tablo 9. Farklı Kırpma Değeri Seçilirse Tüm Modellerin Sonuçları

| MODEL   | RMSE-Train | R2-Train | RMSE-Test | R2-Test |
|---------|------------|----------|-----------|---------|
| LR      | 21.577     | 0.707    | 23.615    | 0.294   |
| SVR     | 20.185     | 0.744    | 19.834    | 0.502   |
| DT      | 19.481     | 0.761    | 22.884    | 0.337   |
| RF      | 19.133     | 0.769    | 21.837    | 0.397   |
| ANN     | 18.405     | 0.787    | 20.711    | 0.457   |
| XGBoost | 18.456     | 0.786    | 21.125    | 0.435   |

Bu iyileştirme ile RMSE ve R2 değerlerinde düşüşler gözlemlenmiştir. Değerler incelendiğinde en iyi sonuç yine ANN modelinde gözlenmiştir.

## 4. BÖLÜM

### SONUÇ

#### 4.1.Sonuç

RUL tahminlemesinin yapılmasının nedeni hataya açık olan uçak motorlarında hatanın daha fazla ilerleyip, motorun çalışmasına engel olacak aşamaya gelmeden önce önleyici aksiyonlar alınmasını sağlayabilmektir.

Bu çalışma kapsamında NASA turbofan veri seti kullanılarak veri odaklı RUL tahmini üzerine çalışmalar yapılmıştır. Veri ön işleme, RUL tahminini etkileyecek özniteliklerin seçimi gerçekleştirilerek, verilerin analiz edilmesi ile Google Colab ortamında Python kodlama dili ile makine öğrenim yöntemleri için en iyi parametre değerleri belirlenerek kurulan modellerden en iyi modelin seçilerek en iyi RUL tahmininin yapılması amaçlanmıştır. RUL tahminin iyi bir şekilde tahmin edilmesi motorlarda oluşan hatanın arızaya dönüşmeden bakım planlanmasını sağlar.

C-MAPPS veri setinin veri miktarının büyük ve çok çeşitli özniteliklere sahip olan bir veri seti olması analizin daha verimli ilerlemesine katkı sağlamıştır. Eğitim seti ve test setlerinin farklı olması aşırı öğrenme durumu oluşmasına engel olmuş ve daha güvenilir sonuçlar elde edilmiştir. RUL değerinin ilk başta doğrusal olarak azaldığı varsayımı ile başlanmış ancak motordaki arızalar başlangıçtan itibaren arızaya başlamadığı için RUL değerinde literatür çalışmalarındaki değere göre düzeltme işlemi uygulanarak sonuçlar incelenmiş ve RMSE ve R2 değerlerinde gözle görülür bir iyileşmeye neden olmuştur. Daha sonra ise kendi belirlediğimiz bir RUL değeri ile düzeltme işlemi uygulanmış ve literatüre göre daha iyi sonuçlar elde edilmiştir.

Makine öğrenme teknikleri ile eğitim seti eğitilmiş ve test setinde bu modeller denenerek performans değerlendirme ölçütlerinden RMSE ve R2 sonuçları elde edilerek en iyi yöntem ANN olarak seçilmiştir.



## KAYNAKÇA

1. EN13306, 2010. Maintenance- Maintenance Terminology. British Standards Institution: London, UK.
2. EN13306, 2010. Maintenance- Maintenance Terminology. European Standard
3. Doyen, L., Gaudoin, O., 2011. Modeling and assessment of aging and efficiency of corrective and planned preventive maintenance. **IEEE Transactions on Reliability**, **60**(4):759-769.
4. Gulati, R., Smith, R., 2009. Maintenance and reliability best practices. **Industrial Press Inc.**
5. Palmer, R., 2013. Maintenance planning and scheduling handbook. **McGraw-Hill Education.**
6. Campbell, J. D., Reyes-Picknell, J. V., Kim, H. S., 2015. Uptime: Strategies for excellence in maintenance management. **CRC Press.**
7. Galar, D., Kumar, U., 2017. Chapter 6-prognosis. **EMaintenance**, 311-370.
8. Mital, A., Desai, A., Subramanian, A., Mital, A., 2014. Product development: a structured approach to consumer product development, design, and manufacture. **Elsevier.**
9. Dashti, R., Daisy, M., Mirshekali, H., Shaker, H. R., Aliabadi, M. H., 2021. A survey of fault prediction and location methods in electrical energy distribution networks. **Measurement**, **184**, 109947.
10. Kaynak, G., 2022. Kestirimci Bakım Planlaması İçin Zaman Serisi Modellerine Dayalı Arıza Zamanı Tahmini, **Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü**, Yüksek Lisans Tezi.
11. Ahmadzadeh, F., Lundberg, J., 2014. Remaining useful life estimation. **International Journal of System Assurance Engineering and Management**, 5:461-474.
12. Si, X. S., Wang, W., Hu, C. H., Zhou, D. H., 2011. Remaining useful life estimation—a review on the statistical data driven approaches. **European journal of operational research**, **213**(1):1-14.

13. Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B., Ziel, F., 2022. Forecasting: theory and practice. **International Journal of Forecasting**, **38**(3): 705-871.
14. Yan, B., Ma, X., Huang, G., & Zhao, Y., 2021. Two-stage physics-based Wiener process models for online RUL prediction in field vibration data. **Mechanical Systems and Signal Processing**, **152**, 107378.
15. Lui, Y. H., Li, M., Downey, A., Shen, S., Nemani, V. P., Ye, H., Hu, C., 2021. Physics-based prognostics of implantable-grade lithium-ion battery for remaining useful life prediction. **Journal of Power Sources**, **485**, 229327.
16. Zeng, Y., Song, D., Zhang, W., Zhou, B., Xie, M., & Tang, X., 2020. A new physics-based data-driven guideline for wear modelling and prediction of train wheels. **Wear**, **456**, 203355.
17. Al-Greer, M., & Bashir, I., 2023. Physics-based model informed smooth particle filter for remaining useful life prediction of lithium-ion battery. **Measurement**, **214**, 112838.
18. Downey, A., Lui, Y. H., Hu, C., Laflamme, S., & Hu, S., 2019. Physics-based prognostics of lithium-ion battery using non-linear least squares with dynamic bounds. **Reliability Engineering & System Safety**, **182**, 1-12.
19. Kang, Z., Catal, C., Tekinerdogan, B., 2021. Remaining useful life (RUL) prediction of equipment in production lines using artificial neural networks. **Sensors**, **21**(3), 932.
20. Mahamad, A. K., Saon, S., Hiyama, T., 2010. Predicting remaining useful life of rotating machinery based artificial neural network. **Computers and Mathematics with Applications**, **60**, 1078-1087.
21. Ansari, S., Ayob, A., Hossain Lipu, M. S., Hussain, A., Saad, M. H. M., 2021. Multi-channel profile based artificial neural network approach for remaining useful life prediction of electric vehicle lithium-ion batteries. **Energies**, **14**(22), 7521.
22. Ahmadzadeh, F., Lundberg, J., 2013. Remaining useful life prediction of grinding mill liners using an artificial neural network. **Minerals Engineering**, **53**, 1-8.

23. Liu, X., Liu, L., Liu, D., Wang, L., Guo, Q., Peng, X., 2020. A hybrid method of remaining useful life prediction for aircraft auxiliary power unit. **IEEE Sensors Journal**, **20**(14), 7848-7858.
24. Zraibi, B., Okar, C., Chaoui, H., Mansouri, M., 2021. Remaining useful life assessment for lithium-ion batteries using CNN-LSTM-DNN hybrid method. **IEEE Transactions on Vehicular Technology**, **70**(5), 4252-4261.
25. Sun, H., Cao, D., Zhao, Z., Kang, X., 2018. A hybrid approach to cutting tool remaining useful life prediction based on the Wiener process. **IEEE Transactions on Reliability**, **67**(3), 1294-1303.
26. Lu, W., Wang, Y., Zhang, M., Gu, J., 2024. Physics guided neural network: Remaining useful life prediction of rolling bearings using long short-term memory network through dynamic weighting of degradation process. **Engineering Applications of Artificial Intelligence**, **Volume 127**, Part B, 107350, 0952-1976,
27. Xiang, S., Qin, Y., Luo, J., Pu, H., Tang, B., 2021. Multicellular LSTM-based deep learning model for aero-engine remaining useful life prediction. **Reliability Engineering & System Safety**, **216**, 107927.
28. Hu, L., He, X., Yin, L., 2023. Remaining useful life prediction method combining the life variation laws of aero-turbofan engine and auto-expandable cascaded LSTM model. **Applied Soft Computing**, **147**, 110836.
29. Mitici, M., de Pater, I., Barros, A., Zeng, Z., 2023. Dynamic predictive maintenance for multiple components using data-driven probabilistic RUL prognostics: The case of turbofan engines. **Reliability Engineering & System Safety**, **234**, 109199.
30. Lei, Y., Li, N., Gontarz, S., Lin, J., Radkowski, S., Dybala, J., 2016. A model-based method for remaining useful life prediction of machinery. **IEEE Transactions on reliability**, **65**(3), 1314-1326.
31. Tian, Z., 2012. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring. **Journal of intelligent Manufacturing**, **23**, 227-237.

32. Ma, M., Mao, Z., 2020. Deep-convolution-based LSTM network for remaining useful life prediction. **IEEE Transactions on Industrial Informatics**, **17**(3), 1658-1667.
33. Costa, N., Sánchez, L., 2022. Variational encoding approach for interpretable assessment of remaining useful life estimation. **Reliability Engineering & System Safety**, **222**, 108353.
34. Li, Y., Chen, Y., Hu, Z., Zhang, H., 2023. Remaining useful life prediction of aero-engine enabled by fusing knowledge and deep learning models. **Reliability Engineering & System Safety**, **229**, 108869.
35. Nieto, P. G., García-Gonzalo, E., Lasheras, F. S., de Cos Juez, F. J., 2015. Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. **Reliability Engineering & System Safety**, **138**, 219-231.
36. Liu, J., Lei, F., Pan, C., Hu, D., Zuo, H., 2021. Prediction of remaining useful life of multi-stage aero-engine based on clustering and LSTM fusion. **Reliability Engineering & System Safety**, **214**, 107807.
37. Zhu, J., Chen, N., Peng, W., 2018. Estimation of bearing remaining useful life based on multiscale convolutional neural network. **IEEE Transactions on Industrial Electronics**, **66**(4), 3208-3216.
38. Khelif, R., Chebel-Morello, B., Malinowski, S., Laajili, E., Fnaiech, F., Zerhouni, N., 2016. Direct remaining useful life estimation based on support vector regression. **IEEE Transactions on industrial electronics**, **64**(3), 2276-2285.
39. Çolak, M. B., Ömer, I. Ş. I. K., Demirtaş, H., Ürgün, S., Ulufer, S., 2016. Turbofan Uçak Motorlarının Uçuşa Elverişli Tutulması İçin Yeni Bir Motor Bakım Sisteminin Tasarımı ve Optimizasyonu. **İstanbul Aydın Üniversitesi Dergisi**, **8**(29), 37-49.
40. Turan, Ö., Karakoç, T. H., 2009. Ardyanmalı ve ayrık akışlı turbofanlarda fan basınç oranı ve bypass oranıyla toplam verimin değişiminin incelenmesi. **Journal of Aeronautics and Space Technologies**, **4**(2), 67-76.
41. Kerrebrock, J. L., 1992. Aircraft engines and gas turbines. **MIT press**.

42. Gökdoğan, Ö. K., 2010. Gaz türbinli motorlarda arıza uyarı ve kontrol sistemi, **Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü**, Yüksek Lisans Tezi.
43. Eren, Y. C., 2023. Gaz türbinli motorların rotordinamik analizlerinin esnek modellerle incelenmesi, **İstanbul Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü**, Yüksek Lisans Tezi.
44. Teubert, C., 2023. NASA'nın Açık Veri Portalı: (<https://data.nasa.gov/Aerospace/CMAPSS-Jet-Engine-Simulated-Data/ff5v-kuh6>), (Erişim tarihi: Ocak 2024).
45. Oğuzlar, A., 2003. Veri Ön İşleme, **Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, Sayı: 21, Temmuz-Aralık, ss. 67-76.
46. Asif, O., Haider, S. A., Naqvi, S. R., Zaki, J. F. W., Kwak, K-S., & Islam, S. M. R., 2022. A Deep Learning Model for Remaining Useful Life Prediction of Aircraft Turbofan Engine on C-MAPSS Dataset. **IEEE Access**, **10**, 95425-95440. [9874872]. <https://doi.org/10.1109/ACCESS.2022.3203406>
47. Kelle, A., Yüce, H., 2022. QTT Tırafiğinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması, **e-ISSN. 2717-8811 JournalMM**, 3(1), 50-62 <https://doi.org/10.55546/jmm.995091>
48. Gültepe, Y., 2019. Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. **Avrupa Bilim ve Teknoloji Dergisi**, **16**, 8-15.
49. Girgin, K. Ç., Zalluhoğlu, C., 2022. Öznitelik-Odaklı Sensör Verisi Bazlı Uçak Motorları Geriye Kalan Faydalı Ömür Tahminleme. **Avrupa Bilim ve Teknoloji Dergisi**, (37), 21-27.
50. Aydın, O. M., Aktaş, R., 2020. Detecting Financial Information Manipulation By Using Supervised Machine Learning Technics: SVM, PNN, KNN, DT. **Uluslararası İktisadi ve İdari İncelemeler Dergisi**, **29**, 165-174. <https://doi.org/10.18092/Ulikidince.748742>
51. Kurt, B., 2018. Tahmin Yöntemleri ile Uçak Verilerinin İşlenmesi, 10179947, (file:///C:/Users/user/Downloads/yokAcikBilim\_10179947.pdf)

52. Kankaya, G., 2022. Kestirimci Bakım Yaklaşımıyla Bir Turbofan Motorunun Çözümlemesi, **Hacettepe Üniversitesi**, Yüksek Lisans Tezi.
53. Lei, Y., Li, N., Guo, L., Li, N., Yan, T., Lin, J. 2018. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. **Mechanical Systems and Signal Processing**, 104, 799-834.
54. Cihan, P., Coşkun, H. 2021. Diyabet Tahmininde Makine Öğrenme Modellerinin Performans Karşılaştırması, **29. Sinyal İşleme ve İletişim Uygulamaları Konferansı (SIU)**, İstanbul, Türkiye, pp. 1-4, doi: 10.1109/SIU53274.2021.9477824.
55. Yıldırım, A., 2021. High-resolution soil salinity mapping using machine learning based regression and classification methods. **İstanbul Teknik Üniversitesi**, Yüksek Lisans Tezi.
56. Zeng, J., Liang, Z., 2022. A Deep Gaussian Process Approach for Predictive Maintenance. **IEEE Transactions on Reliability**, 916 – 933.
57. Özen, N. S., Saraç, S. & Koyuncu, M., 2021. COVID-19 Vakalarının Makine Öğrenmesi Algoritmaları ile Tahmini. **Amerika Birleşik Devletleri Örneği. Avrupa Bilim ve Teknoloji Dergisi**, (22), 134-139.
58. Acar, G., 2022. Zaman Serisi Yöntemleri ve Xgboost Algoritması İle Kömür Satış Tahmini: Türkiye Tarım Kredi Kooperatifleri Uygulaması. **Sakarya Üniversitesi**. Yüksek Lisans Tezi.
59. Akay, Ö., Tunçeli M., 2022. Use of the Support Vector Regression in Medical Data Analysis. **Exp Appl Med Sci**. 2(4):242-56.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı:** SEDA NUR BOZKURT

**Uyruğu:** Türkiye (T.C)

**Doğum Tarihi ve Yeri:**

**Medeni Durum:**

**E-mail:**

**Yazışma Adresi:**

### EĞİTİM

| Derece        | Kurum                                                               | Mezuniyet Tarihi |
|---------------|---------------------------------------------------------------------|------------------|
| Yüksek Lisans | Erciyes Üniversitesi Endüstri Mühendisliği<br>Anabilim Dalı         |                  |
| Lisans        | Erciyes Üniversitesi Mühendislik Fakültesi<br>Endüstri Mühendisliği | 12/06/2019       |
| Lise          | Ufuk Arslan Anadolu Lisesi                                          | 18/06/2014       |

### YABANCI DİL

İngilizce