



**T.C.  
İSTANBUL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**



**Doktora Tezi**

**MODEL TABANLI KESTİRİMCİ BAKIM İLE KALAN FAYDALI  
ÖMÜR TAHMİNİ**

**Engin MÖNGÜ**

**Enformatik Anabilim Dalı**

**Enformatik Programı**

**DANIŞMAN  
Doç. Dr. Hulusi GÜLSEÇEN**

**Aralık, 2022**

**İSTANBUL**

Bu alıřma, 27.12.2022 tarihinde ařağıdaki jüri tarafından Enformatik Anabilim Dalı, Enformatik Programında Doktora tezi olarak kabul edilmiştir.

### **Tez Jürisi**

Do. Dr. Hulusi GÜLSEÇEN(Danışman)  
İstanbul Üniversitesi  
Fen Fakültesi

Prof. Dr. Küçük Hüseyin KOÇ  
İstanbul Üniversitesi-Cerrahpařa  
Orman Fakültesi

Do. Dr. Zümrüt SATI  
İstanbul Üniversitesi  
Siyasal Bilgiler Fakültesi

Do. Dr. Emre AKADAL  
İstanbul Üniversitesi  
İktisat Fakültesi

Dr. Öğr. Üyesi Zerrin AYVAZ REİS  
İstanbul Üniversitesi-Cerrahpařa  
Hasan Ali Yücel Eğitim Fakültesi

### **İntihal Programı Beyanı**

20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

### **Proje Destekleri**

|  |
|--|
|  |
|--|

### **Tezden Üretilmiş Yayınların Künye Bilgileri**

|  |
|--|
|  |
|--|

## ÖNSÖZ

Tez çalışmam boyunca büyük bir sabırla beni destekleyen ve yol gösteren kıymetli danışman hocam Doç.Dr.Hulusi GÜLSEÇEN'e sonsuz teşekkürlerimi sunarım.

Tez izleme komitesinde yer alan ve değerli bilgi ve yönlendirmeleri ile bana destek olan ve akademik anlamda yüksek kaliteye ulaşmamda yardımcı olan çok değerli hocalarım Prof.Dr.Küçük Hüseyin KOÇ ve Doç.Dr.Zümrüt SATI'ya en içten teşekkürlerimi sunarım.

Ayrıca doktora yolculuğum boyunca büyük bir özveri ile beni destekleyen, motive eden aileme teşekkürü bir borç bilir ve en derin sevgilerimi sunarım.

Aralık 2022

Engin MÖNGÜ

# İÇİNDEKİLER

Sayfa No

|                                                                |           |
|----------------------------------------------------------------|-----------|
| ÖNSÖZ .....                                                    | iv        |
| İÇİNDEKİLER.....                                               | v         |
| ŞEKİL LİSTESİ .....                                            | vii       |
| TABLO LİSTESİ.....                                             | x         |
| SİMGE VE KISALTMA LİSTESİ .....                                | xi        |
| ÖZET .....                                                     | xiii      |
| SUMMARY .....                                                  | xvi       |
| <b>1. GİRİŞ.....</b>                                           | <b>1</b>  |
| 1.1. ÇALIŞMANIN KONUSU VE ÖNEMİ.....                           | 1         |
| 1.2. TEZİN KONUSU VE BÖLÜMLERİ .....                           | 2         |
| <b>2. GENEL KISIMLAR.....</b>                                  | <b>5</b>  |
| 2.1. BAKIM YÖNTEMLERİ .....                                    | 5         |
| 2.1.1. Plansız Bakım.....                                      | 5         |
| 2.1.2. Planlı Bakım .....                                      | 6         |
| 2.1.2.1. Periyodik Bakım.....                                  | 6         |
| 2.1.2.2. Bozulma Oranı Değişimi (Küvet Eğrisi).....            | 6         |
| 2.1.2.3. Durum Bazlı Bakım (Condition Based Maintenance) ..... | 7         |
| 2.1.2.4. Kestirimci Bakım (Predictive Maintenance).....        | 11        |
| 2.1.2.4. Önleyici Bakım.....                                   | 14        |
| 2.2. EKONOMİK BAKIM DÜZEYİ.....                                | 15        |
| 2.3. RULMAN YAPISI VE ARIZALARI.....                           | 16        |
| 2.4. LİTERATÜR ARAŞTIRMASI .....                               | 19        |
| <b>3. MALZEME VE YÖNTEM.....</b>                               | <b>24</b> |
| 3.1. KULLANILAN VERİ SETİ VE ÖZELLİKLERİ .....                 | 24        |
| 3.1.1. Test Düzenegi.....                                      | 24        |
| 3.1.2. Veri Yapısı.....                                        | 26        |
| 3.1.3. Test Rulmanları .....                                   | 27        |
| 3.2. DİAGNOSTİK ÇALIŞMASI.....                                 | 28        |
| 3.2.1. Zarf Analizi .....                                      | 29        |
| 3.2.2. Hilbert Dönüşümü .....                                  | 30        |

|                                                                               |            |
|-------------------------------------------------------------------------------|------------|
| 3.3. PROGNOTİK MODELLEME .....                                                | 32         |
| 3.3.1. Öznitelik Çıkarımı (Feature Extraction).....                           | 33         |
| 3.3.2. Dalgacık Dönüşümü (Wavelet Transform): .....                           | 40         |
| 3.3.2.1. Ayrık Dalgacık Dönüşümü (DWT).....                                   | 43         |
| 3.3.3. Öznitelik Seçimi .....                                                 | 46         |
| 3.3.4. Öznitelik Birleştirme ve Sağlık Göstergesinin Elde Edilmesi .....      | 48         |
| 3.3.4.1. Temel Bileşenler Analizi (Principal Component Analysis) .....        | 49         |
| 3.3.4.2. Veri Yumuşatma.....                                                  | 53         |
| 3.3.3.3. Tahmin Başlama Noktasının Belirlenmesi.....                          | 56         |
| 3.3.4.3. Arıza Eşiğinin Belirlenmesi .....                                    | 58         |
| 3.3.5 Üstel Bozulma Modeli.....                                               | 59         |
| 3.3.6 Performans Değerlendirme.....                                           | 64         |
| 3.3.6.1. $\alpha$ - $\lambda$ Doğruluğu ( $\alpha$ - $\lambda$ Grafiği) ..... | 65         |
| 3.3.6.2. Kümülatif Bağlı Doğruluk (CRA) .....                                 | 67         |
| <b>4. BULGULAR.....</b>                                                       | <b>69</b>  |
| 4.1. DİAGNOTİK ÇALIŞMASI BULGULARI .....                                      | 69         |
| 4.2. PROGNOTİK MODELLEME BULGULARI .....                                      | 76         |
| 4.2.1. Test-2 Rulman-1 Veri Seti Prognostik Modelleme .....                   | 76         |
| 4.2.2. Test-1 Rulman-3 Veri Seti Prognostik Modelleme .....                   | 85         |
| <b>5. TARTIŞMA VE SONUÇ .....</b>                                             | <b>93</b>  |
| <b>KAYNAKLAR.....</b>                                                         | <b>98</b>  |
| <b>ÖZGEÇMİŞ .....</b>                                                         | <b>118</b> |

## ŞEKİL LİSTESİ

### Sayfa No

|                                                                                                                                                |    |
|------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1: Asenkron motor arıza oranları. ....                                                                                                 | 3  |
| Şekil 2.1: Bakım yöntemleri [9]. ....                                                                                                          | 5  |
| Şekil 2.2: Küvet eğrisi (bozulma oranının zamanla değişimi) [10]. ....                                                                         | 7  |
| Şekil 2.3: Durum bazlı bakımda temel adımlar [131]. ....                                                                                       | 8  |
| Şekil 2.4: Ekipman (sistem) bozulma süreci [15]. ....                                                                                          | 10 |
| Şekil 2.5: Bakımda temel prognostik yaklaşımları [21]. ....                                                                                    | 13 |
| Şekil 2.6: Prognostik model temel adımları. ....                                                                                               | 14 |
| Şekil 2.7: Bakım yöntemlerinin karşılaştırılması [18]. ....                                                                                    | 15 |
| Şekil 2.8: Ekonomik bakım düzeyinin belirlenmesi. ....                                                                                         | 16 |
| Şekil 2.9: Rulman yapısı [24]. ....                                                                                                            | 17 |
| Şekil 2.10: Rulmanlar için genel PSY yaklaşımı [38]. ....                                                                                      | 20 |
| Şekil 2.11: Rulman diagnostik ve prognostik çalışmalarında yaygın olarak kullanılan<br>öznitelikler ve öznitelik çıkarma yöntemleri [38]. .... | 22 |
| Şekil 3.1: IMS rulman veri seti deney düzeneği. ....                                                                                           | 25 |
| Şekil 3.2: NASA & IMS rulman veri setinde oluşan arızalar (a) iç bilezik hatası (b)<br>yuvarlanma elemanı hatası (c) dış bilezik hatası. ....  | 27 |
| Şekil 3.3: Rexnord ZA-2115 rulman. ....                                                                                                        | 27 |
| Şekil 3.4: Diagnostik model süreç adımları. ....                                                                                               | 28 |
| Şekil 3.5: Dış bilezik arızası olan bir rulmana ait titreşim sinyali. ....                                                                     | 29 |
| Şekil 3.6: Zarf analizi süreç adımları. ....                                                                                                   | 30 |
| Şekil 3.7: Eksenel yüklü rulman sinyali: a) filtrelenmiş ve demodüle edilmiş, b) zarf<br>güç spektrumu. ....                                   | 32 |
| Şekil 3.8: Prognostik model temel adımları. ....                                                                                               | 32 |
| Şekil 3.9: Çarpıklık gösterimleri [90]. ....                                                                                                   | 35 |

|                                                                                                                                                              |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 3.10:</b> Basıklık gösterimleri [90].                                                                                                               | 36 |
| <b>Şekil 3.11:</b> KZFD ile spektral basıklığın hesaplanması.                                                                                                | 39 |
| <b>Şekil 3.12:</b> Dalgacık analizinde ölçek-zaman alanı.                                                                                                    | 41 |
| <b>Şekil 3.13:</b> Dönüşümler için zaman-frekans çözünürlüklerinin karşılaştırılması [180].                                                                  | 42 |
| <b>Şekil 3.14:</b> Bazı ana dalgacık fonksiyonları.                                                                                                          | 43 |
| <b>Şekil 3.15:</b> ADD filtre uygulaması.                                                                                                                    | 44 |
| <b>Şekil 3.16:</b> Yaklaşımlar detaylar ve frekans bantları arasındaki ilişki.                                                                               | 45 |
| <b>Şekil 3.17:</b> Farklı algoritmalar için eğitim ve test doğruluklarının karşılaştırılması a) öz nitelik seçimi yapılmadan b) öz nitelik seçimi yapılarak. | 46 |
| <b>Şekil 3.18:</b> Monoton ve monoton olmayan fonksiyon örnekleri.                                                                                           | 47 |
| <b>Şekil 3.19:</b> Temel bileşen analizi [130].                                                                                                              | 52 |
| <b>Şekil 3.20:</b> SG’de rastgele oluşan anomaliler veya suni dalgalanmaların düzeltilmesi.                                                                  | 54 |
| <b>Şekil 3.21:</b> LOESS yöntemi.                                                                                                                            | 55 |
| <b>Şekil 3.22:</b> Tahmin başlama noktasının gösterimi.                                                                                                      | 56 |
| <b>Şekil 3.23:</b> Üstel bozulma modeli.                                                                                                                     | 62 |
| <b>Şekil 3.24:</b> $\alpha$ - $\lambda$ doğruluk grafiği ve zaman içinde doğruluk konisinin daralması.                                                       | 66 |
| <b>Şekil 3.25:</b> Bağlı doğruluk.                                                                                                                           | 67 |
| <b>Şekil 4.1:</b> 1.test boyunca rulmanlardaki titreşim seviyelerinin değişimi.                                                                              | 69 |
| <b>Şekil 4.2:</b> 2.test boyunca rulmanlardaki titreşim seviyelerinin değişimi.                                                                              | 70 |
| <b>Şekil 4.3:</b> 2.test için 1 saniyelik ve tüm verinin değişimi.                                                                                           | 71 |
| <b>Şekil 4.4:</b> Ham sinyalde BPFO frekansında genlik modülasyonu ve zarf sinyali.                                                                          | 72 |
| <b>Şekil 4.5:</b> Test-2 & Rulman-1 verisi için zarf spektrumu.                                                                                              | 73 |
| <b>Şekil 4.6:</b> 2.test veri setinde baştan sona doğru BPFO genliklerinin değişimi.                                                                         | 73 |
| <b>Şekil 4.7:</b> Test-1 & Rulman-3 verisi için güç spektrumu grafiği.                                                                                       | 74 |
| <b>Şekil 4.8:</b> Test-1 & Rulman-3 verisi zarf spektrumu: a) 0-3000 Hz, b) 0-1000 Hz.                                                                       | 75 |
| <b>Şekil 4.9:</b> BPFO ve BPFI genlik hesaplamasında kullanılan kurtogram fonksiyonu.                                                                        | 77 |
| <b>Şekil 4.10:</b> Hasar frekans genliklerinin hesaplanması.                                                                                                 | 77 |

|                                                                                         |    |
|-----------------------------------------------------------------------------------------|----|
| <b>Şekil 4.11:</b> Test-2 & Rulman-1 BPFO genlik değişimi. ....                         | 78 |
| <b>Şekil 4.12:</b> Test-2 & Rulman-1 BPFI genlik değişimi. ....                         | 78 |
| <b>Şekil 4.13:</b> Test-2 & Rulman-1 verisi için spektral basıklık değişimi. ....       | 79 |
| <b>Şekil 4.14:</b> RMS için gürültü azaltma. ....                                       | 80 |
| <b>Şekil 4.15:</b> Test-2 & Rulman-1 için öznitelik monotonluk seviyeleri. ....         | 81 |
| <b>Şekil 4.16:</b> Test-2 & Rulman-1 için TBA ile elde edilen sağlık göstergesi. ....   | 82 |
| <b>Şekil 4.17:</b> Test-2 & Rulman-1 için LOESS işlemi ve TBN. ....                     | 83 |
| <b>Şekil 4.18:</b> Test2 & Rulman1 için gerçek ve tahmini KFÖ değişimi. ....            | 84 |
| <b>Şekil 4.19:</b> Test2 & Rulman1 için $\alpha$ - $\lambda$ performans grafiği. ....   | 85 |
| <b>Şekil 4.20:</b> Test-1 & Rulman-3 BPFI genlik değişimi. ....                         | 86 |
| <b>Şekil 4.21:</b> Test-1 & Rulman-3 BPFO genlik değişimi. ....                         | 86 |
| <b>Şekil 4.22:</b> Test-1 & Rulman-3 verisi için spektral basıklık değişimi. ....       | 87 |
| <b>Şekil 4.23:</b> Test-1 & Rulman-3 RMS özniteliği için gürültü azaltma. ....          | 88 |
| <b>Şekil 4.24:</b> Test-1 & Rulman-3 için öznitelik monotonluk seviyeleri. ....         | 89 |
| <b>Şekil 4.25:</b> Test-1 & Rulman-3 için TBA ile elde edilen sağlık göstergesi. ....   | 90 |
| <b>Şekil 4.26:</b> Test-1 & Rulman-3 için LOESS işlemi ve TBN. ....                     | 91 |
| <b>Şekil 4.27:</b> Test-1 & Rulman-3 için gerçek ve tahmini KFÖ değişimi. ....          | 92 |
| <b>Şekil 4.28:</b> Test-1 & Rulman-3 için $\alpha$ - $\lambda$ performans grafiği. .... | 92 |

## TABLO LİSTESİ

### Sayfa No

|                                                                                                           |    |
|-----------------------------------------------------------------------------------------------------------|----|
| <b>Tablo 2.1:</b> Rulmanların prognostik ve sağlık yönetimi ile ilgili yayınlanan derleme makaleler [38]. | 23 |
| <b>Tablo 3.1:</b> Quartz ICP 353B33 İvmeölçer teknik özellikleri.                                         | 25 |
| <b>Tablo 3.2:</b> IMS rulman veri seti özellikleri.                                                       | 26 |
| <b>Tablo 3.3:</b> Rulman karakteristik özellikleri.                                                       | 28 |
| <b>Tablo 3.4:</b> Rexnord ZA-2115 rulman karakteristik hasar frekansları.                                 | 28 |
| <b>Tablo 4.1:</b> Test2-Rulman1 verisi için hesaplanan öznitelikler.                                      | 76 |
| <b>Tablo 4.2:</b> Test-2 & Rulman-1 için seçilen öznitelikler ve ilk 15 veri.                             | 81 |
| <b>Tablo 4.3:</b> Test-1 & Rulman-3 için seçilen öznitelikler ve ilk 15 veri.                             | 89 |

## SİMGE VE KISALTMA LİSTESİ

| Simgeler | Açıklama |
|----------|----------|
|----------|----------|

|            |                          |
|------------|--------------------------|
| $\mu$      | : Ortalama değer         |
| $\sigma$   | : Standart sapma (Sigma) |
| $\alpha$   | : Alfa                   |
| $\lambda$  | : Lamda                  |
| $\pi$      | : Pi sayısı              |
| $\theta$   | : Teta                   |
| $\beta$    | : Beta                   |
| $\Phi$     | : Fi (Phi)               |
| $\sigma^2$ | : Varyans                |
| $\Sigma$   | : Toplam (Sigma)         |
| dB         | : Desibel                |
| g          | : G-kuvveti (yer çekimi) |

| Kisaltmalar | Açıklama |
|-------------|----------|
|-------------|----------|

|             |                                                                  |
|-------------|------------------------------------------------------------------|
| <b>ADD</b>  | : Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transformation)      |
| <b>AGF</b>  | : Alçak Geçiren Filtre                                           |
| <b>AI</b>   | : Artifical Intelligence (Yapay Zeka)                            |
| <b>ANN</b>  | : Artifical Neural Network (Yapay Sinir Ağı)                     |
| <b>ARMA</b> | : Autoregressive Moving Average (Otoregresif Hareketli Ortalama) |
| <b>BPFO</b> | : Ball Pass Frequency Outer Race (Dış Bilezik Arıza Frekansı)    |
| <b>BPFI</b> | : Ball Pass Frequency Inner Race (İç Bilezik Arıza Frekansı)     |
| <b>BSF</b>  | : Ball Spin Frequency (Bilye Arıza Frekansı)                     |
| <b>CBM</b>  | : Condition Based Maintenance (Durum Bazlı Bakım)                |
| <b>CMMS</b> | : Computerized Maintenance Management System                     |
| <b>CNN</b>  | : Convolutional Neural Networks (Evrişimli Sinir Ağları)         |
| <b>CI</b>   | : Confidence Interval (Güven Aralığı)                            |
| <b>CRA</b>  | : Cumulative Relative Accuracy (Kümülatif Bağlı Doğruluk)        |
| <b>DBN</b>  | : Deep Belief Network (Derin İnanç Ağları)                       |
| <b>FFT</b>  | : Fast Fourier Transform (Hızlı Fourier Dönüşümü)                |

|              |                                                                                    |
|--------------|------------------------------------------------------------------------------------|
| <b>FTF</b>   | : Fundamental Train Frequency (Kafes Arıza Frekansı)                               |
| <b>HFRT</b>  | : High Frequency Resonance Technique (Yüksek Frekans Rezonans Tekniği)             |
| <b>HI</b>    | : Health Indicator (Sağlık Göstergesi)                                             |
| <b>HHT</b>   | : Hilbert Huang Transform                                                          |
| <b>HMM</b>   | : Hidden Markov Model (Saklı Markov Modeli)                                        |
| <b>IMS</b>   | : Intelligent Maintenance System                                                   |
| <b>KBD</b>   | : Kümülatif Bağlı Doğruluk                                                         |
| <b>KFÖ</b>   | : Kalan Faydalı Ömür                                                               |
| <b>KZFD</b>  | : Kısa Zaman Fourier Dönüşümü                                                      |
| <b>LR</b>    | : Logistic Regression (Lojistik Regresyon)                                         |
| <b>LOESS</b> | : Locally Estimated Scatterplot Smoothing                                          |
| <b>LTSM</b>  | : Long- Short Term Memory (Uzun Kısa Süreli Bellek)                                |
| <b>ML</b>    | : Machine Learning (Makine Öğrenmesi)                                              |
| <b>MSE</b>   | : Mean Squared Error (Ortalama Kare Hatası)                                        |
| <b>MAPE</b>  | : Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)                      |
| <b>NASA</b>  | : National Aeronautics and Space Administration (Ulusal Havacılık ve Uzay Dairesi) |
| <b>NN</b>    | : Neural Network (Sinir Ağları)                                                    |
| <b>PCA</b>   | : Principal Component Analysis (Temel Bileşen Analizi)                             |
| <b>PHM</b>   | : Prognostics and Health Management (Prognostik ve Sağlık Yönetimi)                |
| <b>RA</b>    | : Relative Accuracy (Bağlı Doğruluk)                                               |
| <b>RMS</b>   | : Root Mean Square (Karekök Ortalama)                                              |
| <b>RMSE</b>  | : Root Mean Squared Error (Kök Ortalama Kare Hatası)                               |
| <b>RNN</b>   | : Recurrent Neural Network (Yinelemeli Sinir Ağı)                                  |
| <b>RUL</b>   | : Remaining Useful Life (Kalan Faydalı Ömür)                                       |
| <b>SG</b>    | : Sağlık Göstergesi                                                                |
| <b>STFT</b>  | : Short Time Fourier Transform (Kısa Zaman Fourier Dönüşümü)                       |
| <b>SVM</b>   | : Support Vector Machine (Destek Vektör Makineleri)                                |
| <b>TBN</b>   | : Tahmin Başlama Noktası                                                           |
| <b>WT</b>    | : Wavelet Transformation (Dalgacık Dönüşümü)                                       |
| <b>YGF</b>   | : Yüksek Geçiren Filtre                                                            |

## ÖZET

### DOKTORA TEZİ

#### MODEL TABANLI KESTİRİMCİ BAKIM İLE KALAN FAYDALI ÖMÜR TAHMİNİ

Engin MÖNGÜ

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Enformatik Anabilim Dalı

Danışman : Doç. Dr. Hulusi GÜLSEÇEN

Asenkron motorlar basit yapıları, düşük maliyet ve bakım ihtiyaçları nedeniyle endüstride yaygın olarak kullanılan elektrik makinelerindendir. Fabrikalarda kullanılan makineler ne kadar problemsiz çalışırsa üretim de o kadar sağlıklı olur. Tüm makineler gibi asenkron motorlar da zamanla yaşlanma eğilimi gösterirler ve çeşitli arızalar oluşabilir. Üretimin aksamaması, zaman ve maliyet kaybı yaşanmaması için bu arızaların önceden öngörülebilmesi işletmeler açısından kritik öneme sahiptir. İşletme maliyetlerinin düşürülmesi, operasyonel güvenilirliğin artırılması ve müşteri memnuniyetinin iyileştirilmesi amacıyla motor çalışma ve sağlık durumunun sürekli izlenmesi ve gelişmekte olan arızaların daha büyük maliyetli ve yıkıcı hale gelmeden önce tespit edilmesi gittikçe önem kazanan ve gelişen bir teknoloji haline gelmiştir.

Motorlar çeşitli nedenlerle arızalanabilmekle birlikte mekanik ve elektriksel olmak üzere arızalar iki sınıfa ayrılabilir. Yapılan farklı araştırmalarda motor arızaları içinde ilk sırayı rulman arızalarının aldığı gösterilmiştir. Dolayısıyla rulmanlar en kritik mekanik bileşenler arasındadır ve modern endüstri dönen makinelerinde geniş uygulama alanlarına sahiptir.

Rulmanlar hareketli parçalar arasındaki sürtünmeyi azaltarak veya hareketi istenen yönde kısıtlayarak döner veya doğrusal hareketi kolaylaştırırlar. Genellikle aşırı yük, yüksek hız ve yetersiz yağlama gibi zorlu çalışma ortamlarına maruz kaldıklarından makinenin en savunmasız bileşenidirler. Bu tür çalışma koşulları altında belirli bir zaman sonra, artan boşluk, sürtünme kuvveti, aşırı ısınma, vb. nedenlerle performans düşüşü ve arızalar gelişebilir. Bu arızaların

zamanında tespit edilmemesi ve uygun bakımlarının yapılmaması bozulmaya yol açabilir. Dolayısıyla ekipman üzerinde bazı teknik verilerin (mekanik titreşim, sıcaklık, elektriksel akım, yağ analizi, vb.) sürekli izlenmesi ve durum bazlı bakım senaryolarının uygulanması gereklidir.

Durum bazlı bakım senaryoları temelde prognostik ve diagnostik olmak üzere iki kısımdan oluşmaktadır. Bunlardan prognostik, bozulmanın ilk başladığı andan itibaren arızanın ne zaman oluşacağını tahmin etmekle ilgilenirken, diagnostik ise arıza oluşuktan sonra arızanın tipi, nedeni ile ilgilenmektedir. Bu anlamda prognostik uygulamaları, kayıp oluşmaması ve verimlilik açılarından çok daha etkindir. Durum izleme verilerinin analiz yöntemleri kullanılan algoritma ve veri yapısına göre model tabanlı, veri tabanlı ve hibrit olmak üzere üçe ayrılırlar.

Kestirimci bakımda sensörler kullanılarak ekipmanlardan elde edilen ölçümlerin analiz edilmesi ile ne zaman arıza oluşabileceği önceden tahmin edilmektedir. Kestirimci bakım herhangi bir ekipmanın sağlık durumunun doğru bir şekilde izlenmesi için birtakım teknikler tanımlamaktadır. Bu teknikler lokal veya bulut tabanlı çalışabilen, çeşitli veri analizi ve makine öğrenme algoritmaları içeren teknikler olup diğer bakım yöntemleri olan plansız bakım ve periyodik bakıma göre maliyet avantajı sağlamaktadır.

Bu tez çalışmasında bir asenkron motora bağlanmış bir mil üzerine yerleştirilmiş ve aynı karakteristiğe sahip dört adet rulman üzerinden toplanan titreşim verilerinin analiz edilerek rulmanlarda ne zaman arıza oluşacağını önceden tahmin edilmesi üzerine bir prognostik model geliştirilmiştir. Çalışmada kullanılan veri seti *Center for Intelligent Maintenance Systems (IMS), University of Cincinnati* tarafından kurulan bir deney düzeneği ile toplanmış ve NASA-Prognostics Center of Excellence internet sitesinde araştırmacıların kullanımına açık olarak paylaşılmıştır.

Testler sırasında arıza oluşturacak veya arıza oluşumunu hızlandırıcı herhangi bir ilave işlem uygulanmadan sabit hız ve yük altında mil döndürülerek rulmanların doğal yaşlanma ve arıza oluşma süreçleri beklenmiştir. Mil üzerinde aynı teknik özelliklere sahip dört adet rulman birlikte teste başlamış ve herhangi birinde arıza oluştuğunda test sonlandırılmıştır. Yenilenen rulmanlar ile bu şekilde üç tur test yapılmış ve her seferinde sonunda arıza oluşan üç veri seti paylaşılmıştır. Hangi rulmanda ne arızası olduğu bilgisi de veri sahipleri tarafından paylaşılmıştır.

Titreşim verileri doğal olarak gürültü içerdiğinden öncelikle gürültü azaltma işleminden geçirilmiştir. Ardından titreşim sinyallerinin durağan olmayan yapısı nedeniyle zaman ve frekans bilgilerini aynı anda elde etmek için literatürde yaygın olarak kullanılan ayırık dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümü sonrasında zaman ve frekans domeninde çeşitli öznitelikler hesaplanarak öznitelik tablosu oluşturulmuştur. Tablodaki verilerin belli bir kısmı eğitim verisi olarak kabul edilerek, bu veriler üzerinden monotonluk seviyelerine göre belli sayıda öznitelik seçilmiştir. Bir sonraki veri işleme adımı olarak, seçilen özniteliklere temel bileşenler analizi (PCA) uygulanmış ve rulmanın yaşlanmaya bağlı sağlık durumunu gösteren tek bir büyüklük (sağlık göstergesi) elde edilmiştir. Sağlık göstergesi verisi üzerinde yumuşatma, tahmin başlatma noktası bulma gibi birtakım veri işleme adımları uygulanmış ve işlenmiş sağlık göstergesi verisi üstel bozulma modelinin girişi olarak uygulanmıştır. Varsayılan başlangıç parametreleri ile çalıştırılan model her bir test veri noktası geldiğinde elde edilen çıktı tahmini kalan faydalı ömür bilgisini vermektedir. Geliştirilen prognostik model birinci ve ikinci veri setlerine uygulanmış ve performans ölçümü için  $\alpha$ - $\lambda$  grafiği ile KBD (kümülatif bağıl doğruluk) metrikleri kullanılmıştır. KBD değeri birinci veri seti için 0,74 ve ikinci veri seti içinse 0,85 olarak hesaplanmış olup bu performans değerlerinin bu uygulama

iin yeterli olduėu ve rulmanların kalan faydalı mr tahmininin bařarılı bir řekilde yapılabil-diėi grlmřtr.

Ayrıca diagnostik alıřması da yapılarak zarf analizi tekniėi ile deney sonucunda oluřtuėu belirtilen arızaların varlıėı gsterilmiřtir.

alıřmada uygulanan algoritma ve elde edilen model benzer veri yapısına sahip farklı ekipmanlar iin de kullanılabilir durumdadır. Veri iřleme adımlarında uygulanan yntemler, seilen parametreler ve bazı kabuller iteratif bir řekilde deėiřtirilerek modelin performansı test edilebilir ve artırılabilir.

Aralık 2022, 136 sayfa.

**Anahtar kelimeler:** Kestirimci bakım, rulman, kalan faydalı mr, titreřim analizi, prognostik, stel bozulma modeli

## **SUMMARY**

### **Ph.D. THESIS**

#### **ESTIMATION OF REMAINING USEFUL LIFE WITH MODEL BASED PREDICTIVE MAINTENANCE**

**Engin MÖNGÜ**

**İstanbul University**

**Institute of Graduate Studies in Sciences**

**Department of Informatics**

**Supervisor : Assoc. Prof. Dr. Hulusi GÜLSEÇEN**

Asynchronous motors are widely used in factories due to their several advantages. The healthy continuation of production in enterprises depends on the proper functioning of the devices. Like all equipment, asynchronous motors tend to age over time and various malfunctions may occur. It is critical for businesses to predict these failures in order to prevent production downtime and loss of time and cost. In order to decrease operational expenses, increase operational reliability and end user satisfaction, continuous monitoring of engine operation and health status and detection of developing malfunctions before they become more costly and destructive has become an increasingly important and developing technology.

Motor faults can be basically divided into two categories, electrical and mechanical faults. In different studies, it has been shown that bearing failures take the first place among motor failures. Therefore, bearings are among the most critical mechanical components and have wide applications in modern industrial rotating machinery.

Bearings function to reduce friction between mechanical components or limit movement in the preferred direction. They generally function in harsh operating environments such as overload, high speed and insufficient lubrication.

After a certain period under these circumstances, clearance, frictional force, overheating, etc. performance decrease and failures may develop due to reasons. Failure to detect these faults in a timely manner and to perform proper maintenance may cause to failure. So, it is necessary to constantly monitor some technical data (mechanical vibration, temperature, electrical current, oil analysis, etc.) on the equipment and to apply condition-based maintenance scenarios.

Condition-based maintenance scenarios basically consist of two parts, prognostic and diagnostic. Prognostics is concerned with estimating when the fault will occur from the moment the deterioration first started, while diagnostics is concerned with the type and cause of the fault after it has occurred. In this sense, prognostic applications are much more effective in terms of no loss and efficiency.

The methods used for the analysis of condition monitoring data are basically classified into three categories. These are data based, model based and hybrid approaches that can be considered a combination of these two.

The purpose of predictive maintenance is to predict the failure that will occur, with a high accuracy and sufficiently in advance, when the failure may occur after processing the physical data received from the machinery or equipment via sensors.

Predictive maintenance describes a number of techniques for accurately monitoring the health status of any equipment. These techniques, which can work locally or cloud-based, include various data analysis and machine learning algorithms, provide a cost advantage over other maintenance methods such as reactive or periodic maintenance.

In this study, an algorithm has been developed to predict when a failure will occur in the bearings by analyzing the vibration signal measured from the identical bearings placed on a shaft connected to an induction motor. The data set originally belongs to Center for Intelligent Maintenance Systems (IMS), University of Cincinnati, and shared openly for the use of researchers on the NASA-Prognostics Center of Excellence website.

During the tests, the natural aging and failure processes of the bearings were examined by rotating the shaft under constant speed and load without applying any additional processes that would cause failure or accelerate the occurrence of failure. Four bearings with the same technical specifications on the shaft started the test together and the test was terminated when any of them failed. Three rounds of testing were carried out in this way with the renewed bearings, and three datasets were shared, each one eventually resulting in failure. The information on which bearing and what failure occurred was also shared by the data owners.

Since vibration data naturally contains noise, it was first subjected to noise reduction. Then, discrete wavelet transform has been applied to obtain some features which are characterizing the original vibration signal which is non-stationary. After this process, various frequency and time domain features are extracted and a feature table was created. A certain part of the data in the table is accepted as training data, and a certain number of features were selected according to the monotonicity levels over these data. As the next data processing step, principal components analysis (PCA) was applied to the selected features and a single health indicator was obtained that indicates the aging-related health status of the bearing. Some data processing steps such as smoothing and finding the TSP (time to start prediction) point were applied on the health indicator data, and the final health indicator data was applied to exponential degradation model.

The model run with the default initial parameters gives the estimated remaining useful life information obtained when each test data point arrives. The developed prognostic model was applied to the first and second data sets, and  $\alpha$ - $\lambda$  graph and CRA (cumulative relative accuracy) metrics were used for performance evaluation. The CRA value was calculated as 0.74 for the first data set and 0.85 for the second data set, and it was seen that these performance values were sufficient for this application and the remaining useful life of the bearings could be estimated successfully.

In addition, the presence of faults were shown by performing a diagnostic study and using the envelope analysis technique.

The algorithm applied in the study and the model obtained can be used for other equipment with similar data structures. The accuracy of the algorithm may be tested and increased by iteratively changing the methods applied in the data processing steps, selected parameters and some assumptions.

December 2022, 136 pages.

**Keywords:** Predictive maintenance, bearing, remaining useful life, vibration analysis, prognostic, exponential degradation model

# 1. GİRİŞ

## 1.1. ÇALIŞMANIN KONUSU VE ÖNEMİ

Bir işletme için üretim, sahip olunan tüm kaynakların kullanılarak mal ve hizmet yaratılması şeklinde tanımlanabilir [1]. Daha spesifik olarak ise, makina, malzeme, insan ve enerji kullanarak fiziksel bir varlık veya hizmet ortaya çıkarmak şeklinde de ifade edilebilir. İşletmede kullanılan cihazlar ne kadar problemsiz çalışırsa üretim de o kadar sağlıklı olur.

Zamanla tüm ekipmanlar doğal olarak yaşlanma belirtileri gösterirler ve buna bağlı olarak kendilerinden beklenen fonksiyonlarından uzaklaşabilirler, verimliliklerini kaybederler veya tamamen çalışamaz hale gelebilirler. Sonuçta üretim faaliyetlerinde istenmeyen duruşlar ve dolayısıyla birtakım kayıplar ortaya çıkar. Bakım onarım, bu problemlerin acilen çözülmesi, mümkünse ortaya çıkmasının engellenmesi, işletmedeki tüm cihaz ve sistemlerin uygun şekilde çalışır durumda olmaları için yapılan tüm çalışmaları kapsamaktadır [2].

Son yıllarda teknolojiye yaşanan hızlı değişim, rekabet koşulları ve enerji kısıtları bakım faaliyetlerini daha önemli hale getirmiştir. Robotik sistemler, otomasyon, vb. gibi üretimde kullanılan teknolojik çözümler işçilik maliyetleri azaltmakla birlikte yatırım ve bakım onarım maliyetlerini artırmıştır. Üretimde meydana gelen plansız duruşlar üretim planlarını aksatmakta ve mali kayba yol açabilmektedir [3].

Bu nedenlerle bakım faaliyetleri temelde aşağıdaki amaçlara hizmet etmek için yapılmaktadır: [4]

- Verimliliği en üst düzeye çıkarmak
- Makineler için plansız duruşları düşürmek, işçilik kayıplarını azaltmak,
- Üretim planının aksamadan uygulanmasını temin etmek,
- Üretim kapasitesinin uygun şekilde ve tam olarak kullanılmasını sağlamak,
- Ekipmanların sağlıklı çalışmasını sağlayarak personelin güvenliğini temin etmek,
- Yeterli ve zamanında bakım onarım faaliyetleri ile üretim maliyetlerini azaltmak,
- Yıpranmayı en düşük düzeye indirerek işletmenin değerini korumak,
- Üretimdeki tüm ara çıktı (yarı mamül) ve nihai ürünün kalitesini artırmak,

## 1.2. TEZİN KONUSU VE BÖLÜMLERİ

Üretim sektörü için hızlı, hatasız bir üretim yapmak, maliyetleri düşürmek ve kapasiteyi en verimli şekilde kullanmak en belirgin hedefler arasında sayılabilir. Bu hedefe ulaşmayı engelleyen ve en sık meydana gelen durumlardan birisi ise beklenmeyen ve genelde ani olarak ortaya çıkan arızalar ve üretim hattının durmasıdır. Farklı sektör veya ürünlerin üretimin durmasına göstereceği tolerans farklı olabilir ancak özellikle kritik kabul edilebilecek sektörler için üretimin sağlıklı bir şekilde devam edebilmesi adına Prognostik ve Sağlık Yönetimi (PHM – Prognostic and Health Management) sistemlerinin devreye alınması son derece önemlidir. Prognostik ve Sağlık Yönetimi (PSY), bileşenlerde bir arıza meydana gelmesini tahmin etmeyi ve sonuç olarak karmaşık sistemlerin beklenmedik duruş sürelerini en aza indirmeyi amaçlayan bir bakım politikasıdır. Güncel araştırmalar özellikle PSY gibi tahmine dayalı stratejilerin benimsendiğini göstermektedir. Bu stratejiler makinelere monte edilmiş sensörlerden toplanan ham sinyallerden bilgi çıkarmak ve izlenen ekipmanın kalan faydalı ömrünü (RUL – Remaining Useful Life) hesaplamak için kullanılan Makine Öğrenimi (ML) ve Yapay Zeka (AI) algoritmalarına dayanmaktadır. PSY sistemleri veri toplama, sinyal işleme, diagnostik ve prognostik gibi adımlardan oluşmaktadır [5]. Bu anlamda kestirimci bakım yöntemleri de Prognostik ve Sağlık Yönetiminin bir uygulaması olarak kabul edilebilir.

Asenkron motorlar basit yapıları, düşük maliyet ve bakım ihtiyaçları nedeniyle endüstride yaygın olarak kullanılan elektrik makinalarındandır. Fabrikalarda kullanılan makineler ne kadar problemsiz çalışırsa üretim de o kadar sağlıklı olur. Tüm makineler gibi asenkron motorlar da zamanla yaşlanma eğilimi gösterirler ve çeşitli arızalar oluşabilir.

Motorlar çeşitli nedenlerle arızalanabilmekle birlikte mekanik ve elektriksel olmak üzere arızalar iki sınıfa ayrılabilir. Şekil 1.1’de de gösterildiği gibi Institution of Electrical & Electronics Engineers (IEEE) tarafından yapılan bir anket çalışmasında motor arızaları içinde ilk sırayı %44 ile mekanik arıza sınıfına giren rulman arızaları almaktadır. Yine Electric Power Research Institute (EPRI) tarafından yapılan aynı ankette bu oran %41 olarak belirlenmiştir [6]. Dolayısıyla rulmanlar en kritik mekanik bileşenler arasındadır ve modern endüstride kullanılan döner makinelerde oldukça geniş uygulamalara sahiptir.



**Şekil 1.1:** Asenkron motor arıza oranları.

Rulmanlar çeşitli nedenlerden dolayı yıpranırlar. Bu yıpranmanın belirtileri arasında rulman yüzeyinden parçacıklar kopması, rulmanın aşırı ses çıkarması veya rulmanın deforme olması (aşınma, pullanma, çatlama vb.) gibi sonuçlar sayılabilir [7]. Rulmanda bulunan bilyeler, yük taşıyan yüzeye temas ettiklerinde bir kayma gerilimi oluştururlar. Bu gerilimler yüzeyde çatlak oluşumuna neden olabilir. Rulman dönerken bilye mevcut çatlağın üstünden geçtikçe küçük parçalar koparır rulmanın dönmesini zorlaştırabilir. Rulmanın maksimum devir sayısı ve çalışma süresi de burada kritik parametrelerdendir.

Rulmanın sağlamlık durumu, çalışma koşullarına ve parçalarının dayanıklılığına bağlıdır. Fazla yük ve hız, sürtünme kuvveti, uygun olmayan yağlama ve yanlış montaj gibi nedenler arızaya neden olabilirler.

Bu tezin amacı, rulman arızalarının yıkıcı bir hasara neden olmadan önce kalan ömrünün tahmin edilebilmesi için uygun bir kestirimci bakım modelinin geliştirilmesidir.

Toplam beş bölümden oluşan tezin bu “Giriş” bölümünden sonra gelen “Genel Kısımlar” bölümünde endüstride kullanılan bakım kavramı, çeşitleri, durum bazlı izleme ile ilgili olarak diagnostik ve prognostik kavramları incelenmiştir. Rulmanlar hakkında daha detaylı bilgiler sunularak rulman arızalarının önceden tahmin edilmesi için kullanılan kestirimci bakım yöntemleri ve ilgili literatür araştırması sonuçları paylaşılmıştır.

“Malzeme ve Yöntem” bölümünde çalışma kapsamında kullanılan veriler ve deney düzeneği hakkında detaylı bilgiler verilmiştir. Tahmin için kullanılan modelin akış şeması sunularak veri ön işleme, öznitelik çıkarımı, öznitelik seçimi, veri birleştirme, üstel bozulma modeli gibi adımlar için kullanılan yöntemlerin teorik formülleri paylaşılmış ve teknik açıklamaları yapılmıştır.

“Bulgular” bölümünde uygulanan veri işleme adımlarının sonuçları, seçilen parametreler, varsayımlar ve sonuçta elde edilen tahmin performansları paylaşılmıştır. Uygulanan modelin iki farklı veri seti için de çalıştığı gösterilmiş ve elde edilen tahmin performansları görsel ve sayısal olarak karşılaştırılmıştır.


Son bölüm olan “Tartışma ve Sonuç” bölümünde ise modelin kullanılabilirliği, literatüre yapılan katkı, farklı sistemler için tekrarlanabilirliği, sınırlılıkları değerlendirilerek, ileride yapılacak farklı çalışmalar için önerilerde bulunulmuştur.



## 2. GENEL KISIMLAR

### 2.1. BAKIM YÖNTEMLERİ

Farklı kaynaklarda isimlendirme farklılıkları bulunmakla beraber endüstride kullanılan bakım yöntemlerini temelde Şekil 2.1’de gösterildiği gibi sınıflandırmak mümkündür.



Şekil 2.1: Bakım yöntemleri [9].

#### 2.1.1. Plansız Bakım

Bu yöntemde ekipmanda arıza oluştuğunda müdahale edilir. “Düzeltilici Bakım” olarak da isimlendirilir. Bu yöntemde arızanın oluşması beklendiğinden her işletme ve sektör için uygun değildir [4]. Arıza oluştuğunda üretim kaybı veya gecikmesi fazla olmakla birlikte ekipman tamirinin nispeten kolay ve ucuz yapılabildiği durumlar için uygun olabilir ve daha az personel ile bakım faaliyetleri yürütülebilmektedir. Arızanın oluşmasına izin verilmesi güvenlik riskini de beraberinde getirmektedir. Oluşan arızanın makineye kalıcı zarar verme riskinin yanında operatör açısından da çeşitli tehlikelere davetiye çıkarması mümkündür.

### 2.1.2. Planlı Bakım

Plansız bakım yönetiminin dezavantajları nedeniyle zaman içinde planlı bakım yöntemleri tercih edilmeye başlanmıştır. Planlı bakım yöntemlerinde arıza oluşma koşulu yoktur [2]. Bu yöntemde tedarikçi firmalardan alınan bakım bilgileri doğrultusunda ve işletmenin kendi tecrübelerinden faydalanılarak ekipmanlar için periyodik bakım faaliyetleri uygulanmaktadır.

Periyodik bakım sayesinde birçok arıza önceden belirlenir, düşük maliyetle ve daha önemli bir hasara yol açmadan problem giderilebilir. Planlı bakımın verimli ve faydalı olabilmesi için ekipman parçaları kontrol altında tutularak ömürlerinin artırılması sağlanmalıdır. Süreklilik sayesinde zamanla bu faaliyetlerin daha iyi sonuçlar vermeye başlayacağı da bilinmelidir. Planlı bakım yöntemleri üç grupta tanımlanabilir [9].

#### 2.1.2.1. Periyodik Bakım

Periyodik bakımda temel amaç makine ömrünü uzatmak ve istenmeyen üretim duruş ve kayıplarını minimize etmektir [9]. Bu yöntemde, arıza oluşması beklenmeden ekipman için önceden tanımlanmış bakım faaliyetleri belli periyotlarda uygulanarak arıza oluşması engellenmeye çalışılmaktadır.

İşletme bakım personelinin tecrübesi ve ekipmanların geçmiş performans ve çalışma koşulları referans alınarak ve en önemlisi üretici firmanın önerilerine istinaden makineye nasıl bir plan dahilinde bakım yapılacağı önceden belirlenmiştir. Bu bakımlar genellikle gün, hafta, ay veya yıl bazında periyodik olarak planlanır.


Bu yöntemde işletmeler eğer var ise kendi teknik uzmanlarını kullanabilir veya bu hizmeti diğer yetkili firmalardan satın alabilirler. Bu bakım yönteminde bakım süresi minimum tutularak makine kullanılabilirlik oranının artması sağlanır. Ayrıca olası daha büyük arızaların önüne geçildiği için bakım maliyeti düşürülmüş ve ekipmanların normalden daha erken yıpranması önlenmiş olur [4].

#### 2.1.2.2. Bozulma Oranı Değişimi (Küvet Eğrisi)

Bir ekipman veya bileşenin ekonomik ömrü boyunca bozulma oranı değişimi Şekil 2.2’de gösterildiği gibi bir eğri şeklinde ifade edilmektedir [10]. Tüm parçalar ve makine ömrü, alışma (bebeklik), olgunluk (normal çalışma) ve yorulma (yaşlanma) evrelerinden oluşur. Ekipmanın

kullanılmaya başlanmasıyla ardından stabil duruma gelene kadar geçen sürede arıza oluşma olasılığı yüksek bir orandan başlayarak zaman içinde düşmeye başlar. Olgunluk döneminde yaklaşık sabit bozulma oranına sahiptir. Yaşlılık döneminde ise arızalanma oranı sürekli artma eğilimindedir [10]. Farklı dönemlerde oluşan arızaların nedenleri genelde farklıdır. Bu nedenle her dönem için alınan önlemler de farklı olmalıdır.

İlk dönemde oluşan arızalar genelde tasarım ve imalat hatalarından kaynaklanır. Bunları önlemek için tasarım ve üretim aşamalarında çeşitli testler planlanabilir. Rastgele arızaların görüldüğü olgunluk dönemindeki arızalar, genelde kullanım kaynaklıdır. Bu konuda iyileştirme sağlanması için kullanıcı operatörlerin eğitimi önemlidir. Yaşlanma dönemindeki arızaların sebebi ise ekipman ve bileşenlerin kendi doğal ömürlerini tamamlamalarıdır. Bu evrede çeşitli önleyici bakım faaliyetleri ile bileşen ömrü mümkün olduğunca uzatılmaya çalışılmalıdır.




Şekil 2.2: Kuvvet eğrisi (bozulma oranının zamanla değişimi) [10].

### 2.1.2.3. Durum Bazlı Bakım (Condition Based Maintenance)

Modern teknolojinin hızlı gelişimi ile ürünler daha karmaşık hale gelirken daha iyi kalite ve daha yüksek güvenilirlik de gerekli hale gelmiştir. Bu durum doğal olarak periyodik bakım maliyetlerini de giderek yükseltmiştir ve sonuçta bakım faaliyetleri birçok endüstriyel şirket için önemli bir maliyet kalemi haline gelmiştir. Bu duruma bir çözüm olarak durum bazlı bakım

(CBM-Condition Based Maintenance) gibi daha verimli bakım yaklaşımları gündeme gelmiştir [11].

Durum bazlı bakım, ekipman durumunun durum izleme teknolojileri aracılığıyla izlendiği bir bakım metodolojisi. Sensörler (veya el tipi ekipmanla yapılan testler) ekipmanda bir sorun yaşandığını gösterdiğinde bakım çalışması gerçekleştirilir. Bir CBM programı, düzgün bir şekilde kurulur ve etkin bir şekilde uygulanırsa, gereksiz planlanmış periyodik bakım işlemlerinin sayısını azaltarak bakım maliyetini önemli ölçüde azaltabilir [11]. Şekil 2.3'te gösterildiği gibi durum bazlı bakım programı veri toplama, veri işleme ve bakım kararı verme adımlarından oluşur.



**Şekil 2.3:** Durum bazlı bakımda temel adımlar [131].

Veri toplama, durumu izlenecek ekipmanlardan faydalı verilerin toplanması ve depolanması sürecidir. Bu süreç, makine arızasının teşhis edilmesi ve prognostik uygulaması için önemli bir adımdır. Bir durum izleme programında toplanan veriler olay verileri ve durum izleme verileri olmak üzere iki ana tipte kategorize edilebilir. Olay verileri, ekipman üzerinde geçmişe dönük olarak uygulanan işlemler ve nedenleri (örneğin; kurulum, arıza, revizyon, küçük onarım, periyodik bakım, yağ değişimi vb.) hakkındaki bilgileri içerir. Durum izleme verileri ise bizzat ekipman üzerinden alınan ve ekipmanın sağlık durumu ile ilgili teknik ölçümlerdir. Örneğin; titreşim verileri, akustik veriler, yağ analiz verileri, sıcaklık, basınç, nem, hava veya çevre verileri durum izleme verisi olarak kullanılabilir. Mikro sensörler, ultrasonik sensörler, akustik emisyon sensörleri gibi çeşitli sensörler, farklı veri türlerini toplamak üzere tasarlanmıştır [12, 13]. Bluetooth gibi kablosuz teknolojiler, uygun maliyetli veri iletişimine alternatif bir çözüm sağlamıştır. Bilgisayarlı bakım yönetim sistemleri (CMMS - Computerized Maintenance Management System), kurumsal kaynak planlama sistemleri gibi bakım bilgi sistemleri, veri depolama ve işleme için geliştirilmiştir [14]. Olay verilerinin toplanması genellikle bilgi sistemlerine manuel veri girişi gerektirir. Bilgisayar ve sensör teknolojilerinin hızlı gelişimi

sayesinde veri toplama sistemleri ve teknolojileri daha güçlü ve ucuz hale gelmiş, bu da durum izleme uygulamaları için veri toplamayı daha ekonomik ve uygulanabilir hale getirmiştir. Özellikle olay verilerinin ve durum izleme verilerinin durum izlemede eşit öneme sahip olduğu unutulmamalıdır [11].


Veri işlemenin ilk adımı veri temizlemedir. Veriler, özellikle manuel olarak girilen olay verileri genelde hata içerir. Veri temizleme, analiz ve modelleme için hatasız verilerin kullanılmasını sağlar veya en azından bu şansı artırır. Veri hataları sensör hataları veya insan kayıt hataları gibi birçok faktörden kaynaklanabilmektedir ve genel olarak, verileri temizlemenin basit bir yolu yoktur. Bazen verilerin manuel olarak incelenmesi gerekebilir. Grafikselleştirme araçları, veri hatalarını bulmak ve kaldırmak için yardımcı olabilir.

Veri işlemenin bir sonraki adımı veri analizidir. Verilerin daha iyi anlaşılması ve yorumlanması için literatürde çeşitli veri analizi model, algoritma ve araçları bulunmakta olup bunların seçimi temelde toplanan veri türüne bağlıdır.

Diagnostik ve prognostik çalışması amacıyla dalga biçimini analiz ederek faydalı bilgiler çıkarmak için çeşitli sinyal işleme teknikleri geliştirilmiştir. Ham sinyallerden faydalı bilgilerin çıkarılması işlemi, öznel özellik çıkarma (feature extraction) olarak isimlendirilmektedir.

Durum izleme programının son adımı ise bakım kararının verilmesidir. Bir CBM programında bakım karar desteği için kullanılan teknikler diagnostik ve prognostik olmak üzere iki ana kategoriye ayrılabilir. Diagnostik, daha çok arıza meydana geldiğinde arızanın tespit edilmesi ve tanımlanması ile ilgilenirken prognostik kavramı arızaları meydana gelmeden önce tahmin etmeye odaklanır. Prognostik çalışmasında temel amaç izlenen ekipmanın kalan faydalı ömrünü (RUL-Remaining Useful Life) tahmin etmektir. Kalan faydalı ömür, mevcut ekipmanın yaşı ve durumu ve geçmiş çalışma profiline bağlı olarak arızayı gözlemlemeden önce kalan süre olarak tanımlanmaktadır.

Prognostik uygulamalar, bozulmanın ilk algılandığı nokta ile tam arıza oluşması arasında uygulanmaktadır. Diagnostik uygulamaları ise arıza oluşması durumunda uygulanır. Şekil 2.4'te bu durum ifade edilmiştir. Sonuç olarak, iki uygulamanın amaçları farklıdır, ancak ikisi de Prognostik ve Sağlık Yönetimi'nin bir parçasıdır. Her iki uygulama da durum bazlı bakım alanında uygulandığı için durum bazlı veri toplama ve sinyal işleme ile ilgili benzer aşamalar içerirler [15].



Şekil 2.4: Ekipman (sistem) bozulma süreci [15].

Prognostikte ana amaç ileriye dönük bir tahmin yapmak olduğundan ve bu süreç belirsizlik içerdiğinden dolayı, prognostik yaklaşımlar aşağıdaki bazı varsayımlar üzerine kuruludur [16]:

- Tüm elektromekanik sistemler kullanım şekli, süresi ve çevresel koşullara bağlı olarak yaşlanırlar.
- Bileşenlerin yaşlanması ve hasar birikimi fiziksel ve kimyasal olarak kendini gösteren monotonik süreçlerdir.
- Arıza tam anlamıyla oluşmadan önce yaşlanma belirtileri (doğrudan veya dolaylı) önceden tespit edilebilir.
- Yaşlanma belirtilerini bileşenin bozulma modeli ile ilişkilendirmek mümkündür. Böylece bağımsız bileşenlerin kalan faydalı ömürleri tahmin edilebilir.

Prognostik uygulamaları, oluşacak ekstra bakım maliyetlerini engellemesi nedeniyle diagnostiğe göre daha üstün kabul edilmekle birlikte, pratikte hiçbir yöntem ile arızaları %100 tahmin etmek mümkün olmadığından diagnostiğin yerini tamamen alamamaktadır. Ayrıca diagnostik çalışmaları daha iyi prognostik modeller geliştirilebilmesi için veri sağlaması ve sistem tasarımının güncellenebilmesi için faydalı bir geri besleme kaynağı olarak ta kullanılabilir.

#### 2.1.2.4. Kestirimci Bakım (Predictive Maintenance)

Kestirimci bakım, makina veya ekipmanlardan sensörler aracılığı ile alınan ölçümlerin çeşitli veri işleme adımlarından geçirilmesinden sonra ekipmanda ne zaman arıza oluşabileceğini mümkün olduğu kadar doğru ve önceden tahmin etme prensibine dayanmaktadır. Bu anlamda kestirimci bakım sistemleri, sadece belirli anomali durumları oluştuğunda uyarı veren durum bazlı izleme sistemlerinin bir adım ötesi olarak düşünülebilir.

Kestirimci bakım herhangi bir ekipmanın sağlık durumunun doğru bir şekilde izlenmesi için birtakım teknikler tanımlamaktadır. Bu teknikler lokal veya bulut tabanlı çalışabilen, çeşitli veri analizi ve makine öğrenme algoritmaları içeren teknikler olup diğer bakım yöntemleri olan plansız bakım ve periyodik bakıma göre maliyet avantajı sağlamaktadır.

Kestirimci bakımdaki hedeflerden biri ekipman ile ilgili olası arızayı belirlemek, diğeri ise ekipmanı durum verileri ile sürekli izleyerek arızanın ne zaman oluşabileceğini tahmin etmektir. Başarılı yapılacak bir tahmin sayesinde tamir süresi ve oluşan maliyetler minimum seviyede tutulabilmektedir. Planlı bakımdan farklı olarak bu yöntemde periyodik değil durum bazlı olarak bakım yapılmaktadır. Bu şekilde bakım faaliyetleri optimize edilerek minimum maliyet ve maksimum üretim verimi elde edilmektedir.

Kestirimci bakım yöntemleri makinelerin teknik spesifikasyonları, geçmiş bakım bilgileri ve çeşitli ölçüm yöntemleri ile elde edilen çalışma şartları gibi birçok veriyi kullanarak cihazların performans durumunu, olası arızalarını ve bakım planlaması ile ilgili bilgileri sunar. Bu sayede diğer yöntemlere göre aşağıda özetlenen bazı avantajlara sahiptir [17]:

- Arızanın zamanı tahmin edilebildiğinden en uygun tamir zamanı kolaylıkla belirlenebilir. Üretim ve ürün kaybı minimum olur.
- Ekipmanın bakımı ve korunması için harcanan toplam süre azaltılmış olur.
- Yıkıcı hasarlar önlendiği için toplam bakım maliyetleri düşer ve arıza oluşmadığı için bakımlar da nispeten kolay olur.
- Ekipmanlar daha uzun süre kullanılabilir ve daha güvenilir olduğu için üretim planlaması optimum seviyede yapılabilir.


Bu avantajları sayesinde kestirimci bakım teknolojilerine ait pazarın mali büyüklüğünün 2022 yılının sonunda 10,96 milyar USD olması beklenmektedir. Bu artışın nedenleri olarak;

kestirimci bakım çözümleri içeren iş modellerinin artması, nesnelerin interneti ve kestirimci bakım uygulamaları için uzman personel katılımının artırılması, IoT (nesnelerin interneti) teknoloji maliyetlerinin nispeten düşmesi, sadece durum bazlı izleme teknolojilerinin kestirimci bakım teknolojileri ile yer değiştirmesi gösterilebilir [18].

Kestirimci bakım yöntemlerinin uygulanması ile ilgili çeşitli zorluklar da mevcuttur. Bunlar özetle aşağıdaki gibi sıralanabilir [19, 20]:

- Farklı kaynaklardan farklı formatlarda elde edilen verilerin entegrasyonu,
- Analiz için yeterli ve kaliteli verinin temin edilmesi,
- Modelleme için yeterli arıza verisinin bulunmaması,
- Mevcut analiz yöntem veya modellerinin hangisinin kullanılacağına bilinmemesi,
- Verilere erişimin güvenlik ve gizlilik politikaları nedeniyle sınırlı olabilmesi,
- Sayısal olmayan bilgilerin indekslenmesi,
- Zamanla oluşan büyük verinin işlenmesi ve sonuç elde edilmesi için harcanan zaman,
- Başlangıçta yatırım maliyetinin yüksek olabilmesi,
- İşletmelerde ve kuruluşlarda bilgi, uzmanlık ve altyapı eksikliği olabilmesi.


Kestirimci Bakımın ana amaçlarından biri olan prognostik modelleme yapmak ve izlenen ekipmanın kalan faydalı ömrünü (KFÖ) tahmin etmek için literatürde kullanılan yöntemler farklı kaynaklarda bazı farklılıklar göstermekle birlikte temel olarak 4 kategoriye ayrılabilir. Bu kategoriler Şekil 2.5'te gösterilmiştir [21].



**Şekil 2.5:** Bakımda temel prognostik yaklaşımları [21].

Model tabanlı yöntemler, matematiksel ve fiziksel modelleri kullanarak sistem davranışını anlamak için kullanılmaktadır. Matematiksel, simülasyon ve deneysel olmak üzere üç sınıfa ayrılmaktadır. Simülasyon modelleri, bazı değişkenlerin ve değişikliklerin sisteme etkisinin değerlendirilmesi için kullanılır. Deneysel modeller, oluşturulmuş çalışma şartlarında ve yetkin kişiler tarafından yapılmış prototipler ile oluşturulmuş modellerdir. Sistem sinyallerinin işlenmesi ile elde edilen zaman ve frekans alanı verilerini kullanan modeller ise matematiksel model olarak isimlendirilmektedir [22].

Bu tez çalışmasında model tabanlı bir kestirimci bakım algoritması geliştirilmiştir. Kalan faydalı ömür tahmini için kullanılan prognostik modelinin ana adımları Şekil 2.6’da verilmiştir. Modelin detayları ise ilerleyen bölümlerde açıklanacaktır.




Şekil 2.6: Prognostik model temel adımları.

#### 2.1.2.4. Önleyici Bakım

Ana amacı arızaların ortaya çıkarılması yerine oluşmasının önlenmesi olan yeni bir bakım yöntemidir. Bu yöntemde ekipman tasarımı ve işletme koşullarında yapılacak değişiklikler ile arızaların sebeplerinin ortadan kaldırılması hedeflenmektedir. Bu amaca ulaşabilmek için işletme içinde yoğun araştırma ve geliştirme faaliyetlerinin yapılması gerekmektedir. Bu nedenle her işletme için uygun olmayıp, bu kapasite ve yetkinliği olan büyük ölçekli işletmeler için daha uygulanabilir bir yöntemdir [9].

Buraya kadar anlatılan bakım yaklaşımlarının uygulamadaki farklılıkları tezin de konusu olan asenkron motor arızası örneği üzerinde aşama aşama gösterilerek Şekil 2.7’de vurgulanmaya çalışılmıştır [18].




Şekil 2.7: Bakım yöntemlerinin karşılaştırılması [18].

## 2.2. EKONOMİK BAKIM DÜZEYİ

Kontrol, değişim ve tamir gibi bakım faaliyetlerinin artırılması planlı bakım maliyetlerini artırmaktadır. Bununla birlikte, arıza kaynaklı onarım maliyetleri, ani oluşan üretim kayıpları ve dolaylı maliyetler ise azalmaktadır. Şekil 2.8’de de görüldüğü gibi, bakım düzeyi düşürülürse, doğrudan oluşan arızanın tamiri için harcanan arıza bakım maliyeti ve üretimin durması nedeniyle oluşan üretim kaybı ve diğer dolaylı maliyetler söz konusu olmaktadır.

Planlı bakım düzeyi arttıkça onarım ve diğer dolaylı maliyetler azalmaktadır. Belli bir noktaya kadar oluşan toplam maliyet azalmakla birlikte planlı bakım düzeyi artmaya devam ederse toplam maliyet te artışa geçmektedir. Bu nedenle maliyetler açısından optimum bakım düzeyinin belirlenmesi önemlidir. Ekonomik bakım düzeyi oluşan toplam maliyet açısından en düşük noktayı temsil etmektedir. Bu düzey belirlenirken sadece maliyetler değil iş güvenliği, güvenilirlik, kullanılabilirlik gibi parametreler de dikkate alınmalıdır [10].



Şekil 2.8: Ekonomik bakım düzeyinin belirlenmesi.

### 2.3. RULMAN YAPISI VE ARIZALARI

Rulmanlar, modern endüstride kullanılan dönen makinelerin en kritik mekanik bileşenleri arasındadır ve çok geniş uygulama alanlarına sahiptir. Rulman kelimesi dilimize Fransızca “roulement” kelimesinden (“yuvarlanma” anlamında) geçmiştir [23].


Rulmanlar hareketli parçalar arasındaki sürtünmeyi azaltarak veya hareketi istenen yönde kısıtlayarak döner veya doğrusal hareketi kolaylaştırırlar. Genellikle aşırı yük, yüksek hız ve yetersiz yağlama gibi zorlu çalışma ortamlarına maruz kaldıklarından makinenin en savunmasız bileşenidirler [38]. Bu tür çalışma koşulları altında belirli bir zaman sonra, artan boşluk, sürtünme kuvveti, aşırı ısınma, vb. nedenlerle performans düşüşü ve arızalar gelişebilir. Bu arızaların zamanında tespit edilmemesi ve uygun bakımlarının yapılmaması bozulmaya yol açabilir. Dolayısıyla ekipman üzerinde bazı teknik verilerin (mekanik titreşim, sıcaklık, elektriksel akım, yağ analizi vb.) sürekli izlenmesi ve durum bazlı bakım senaryolarının uygulanması gereklidir [38].

Rulmanlar; temelde bir kafes yapısı, iç bilezik, dış bilezik ve ikisinin arasında dönen bilyelerden oluşur. Rulman minimum sürtünme ile dönme hareketini kolaylaştırır. Rulman bileşenlerinin güvenilirliği büyük oranda kullanılan malzemelere bağlıdır. Bu malzemeler yüklere karşı dirençli olmalı ve belirli uygulamalara göre tasarlanmalıdır. Bilezikler ve yuvarlanma elemanları için temel olarak tamamen sertleştirilmiş krom çeliği kullanılmaktadır. Rulmanlar

için presli çelik levhadan yapılan kafesler genellikle düşük karbonlu çelikten imal edilmektedir. Uygulama amacı ve ortamına bağlı olarak pirinç veya paslanmaz çelik kullanılabilir [8].

Rulmanda bir arıza oluştuğunda veya yıpranmanın etkisiyle çeşitli frekanslarda titreşimler oluşur. Bu titreşimler, rulman bileşenleri üzerinde ve rulmanın yapısal tasarımına bağlı olarak birbirinden bağımsız frekans bileşenleri oluşturur. Bu frekanslar oluşan hata ve seviyesi ile ilgili bilgi vermektedir. Rulmanın dönüş hızı arttıkça bilyenin arızalı noktadan geçiş sıklığı da artacağından hata frekansı da değişecektir [23].

Rulmanda oluşan hasarı karakterize eden dört çeşit hasar frekansı bulunmaktadır. Bunlar iç ve dış bilezik, kafes ve yuvarlanma elemanı frekanslarıdır. Şekil 2.9'da tipik bir rulman yapısı görülmekte olup,  $D_b$  bilye çapı,  $D_c$  kafes dairesi çapı ve  $\beta$  da temas açısını ifade etmektedir.



Şekil 2.9: Rulman yapısı [24].

Oluşan hasar frekansları ise aşağıdaki eşitlikler ile teorik olarak hesaplanabilmektedir [24].

$$F_{kafes} = \frac{1}{2} F_r \left( 1 - \frac{D_b \cos \beta}{D_c} \right) \quad (1)$$

$$F_{diş} = \frac{n}{2} F_r \left( 1 - \frac{D_b \cos \beta}{D_c} \right) \quad (2)$$

$$F_{iç} = \frac{n}{2} F_r \left( 1 + \frac{D_b \cos \beta}{D_c} \right) \quad (3)$$

$$F_{bilye} = \frac{D_c}{D_b} F_r \left[ 1 - \left( \frac{D_b \cos \beta}{D_c} \right)^2 \right] \quad (4)$$

Bu eşitliklerde  $n$  yuvarlanma elemanı (bilye) sayısını,  $F_r$  ise şaft devrini belirtmektedir.

Bununla birlikte bazı rulman arıza nedenleri olarak; yetersiz yağlama, aşırı veya ters yükleme, aşırı ısınma, gevşeklik, elektrik kaçağı, eksen kaçıklığı, korozyon ve montaj hataları sayılabilir [25]. Bu hatalar çeşitli çevresel faktörler ve insan hataları sebebiyle yüksek seviyede rastgelelik içerirler [26].

Rulman arızalarının tespit edilmesi için literatürde çoğunlukla titreşim ve akım sinyallerinden faydalanılmıştır. Dalgacık analizi, yapay zeka, bulanık mantık, vb. yöntemler ile de kestirimci bakım çalışmaları yapılmıştır [27-34].


Titreşim sinyali analizi rulman arızalarının teşhisinde kullanılan geleneksel bir yöntemdir. Titreşim sinyali zaman, frekans veya zaman-frekans domeninde analiz edilerek çeşitli arızalar tespit edilebilir [35]. Arızaların önceden tespit edilebilmesi verimli ve düşük maliyetli bir üretim için oldukça kritiktir. Bunu sağlayabilmek için yapılacak prognostik çalışmasının başarılı olabilmesi için sinyal analizi aşamasında kullanılacak özniteliklerin kalitesi de kritik öneme sahiptir [26].

Bir rulman bozulma sürecine başladığında, titreşim spektrumunda rulman arızalarıyla ilişkili çok yüksek frekanslı (5-40 kHz veya seviye 1) bileşenler ortaya çıkmaya başlar. İkinci aşamada yüksek frekans bileşenlerine ek olarak orta frekans (1-5 kHz veya seviye 2) de ortaya çıkmaya başlar. Ancak bu seviyelerdeki arızaları tespit etmek zordur. Ardından, arızayla ilişkili frekans bileşenleri, titreşim spektrumunda düşük frekans aralığında (< 1 kHz veya seviye 3) görülebilir. Daha önce bahsedildiği gibi hasar ya da karakteristik frekanslar olarak adlandırılan ve geometriye, yatağın boyutlarına ve dönme hızına bağlı olan bu frekanslar verilen eşitliklerden

hesaplanabilir. Dördüncü seviyede, rulman tam bir arızaya gider ve titreşim spektrumu gürültülü bir hale gelir. Bu evre, acil önlem alınması gereken, rulman ömrünün sona yaklaştığı evredir. Bu nedenle, rulman arızalarının teşhisi için teorik rulman hasar frekanslarının yer aldığı seviye 3'e odaklanmalıdır [36, 37].

## 2.4. LİTERATÜR ARAŞTIRMASI

Herhangi bir endüstride oluşacak ani bir rulman arızası, makine ve üretim duruş süresi nedeniyle büyük ekonomik kayıplara neden olabilir. Makine duruş süresi, doğrudan ve dolaylı kayıplara yol açabilir ve bunlar maddi ve maddi olmayan şekilde iki geniş kategoriye ayrılabilir. Maddi maliyetlerin hesaplanması nispeten kolaydır ve makineyi onarmak için gereken işçilik, malzeme ve diğer kaynakların maliyetini içerirken, maddi olmayan maliyetler tam bir kesinlik derecesinde değerlendirilemez ve atıl işçilik maliyetlerinden, üretimi telafi etmek için oluşacak fazla mesai ödemelerinden, üretim mallarının geç teslimatı nedeniyle oluşabilecek ceza maliyetleri, vb.'den oluşabilir. Yukarıda belirtilen durumlar göz önüne alındığında, rulman arızalarının prognostik ve sağlık yönetiminin ne denli önemli olduğu anlaşılabılır. Güvenilirliği ve kişisel güvenliği artırmak ve buna bağlı olarak ekipman arıza süresini ve arıza maliyetini azaltmak için rulmanların prognostik ve sağlık yönetimi özelinde uzun yıllardır araştırma ve geliştirme çalışmaları yapılmaktadır [38]. Şekil 2.10'da endüstriyel uygulamalarda rulmanlar için PSY'nin geliştirilmesi ve uygulanması için sistematik bir yaklaşım gösterilmektedir.



Şekil 2.10: Rulmanlar için genel PSY yaklaşımı [38].

Bu bölümde literatürde rulmanlar için yapılan diagnostik ve prognostik çalışmalarında kullanılan makine öğrenmesi teknikleri derlenmiştir. Literatürde prognostik nispeten daha yeni ve gelişmekte olan bir alan olduğundan bu alanda yapılan çalışmaların diagnostik alanında yapılan çalışmalara göre daha az olduğu görülmektedir.

Kestirimci bakım amacıyla rulmanlar için en çok titreşim verisi kullanılmakla birlikte yağ analizi ve akustik emisyon ölçümü de kullanılan ölçümler arasındadır. Prognostik ve sağlık yönetimi açısından kullanılacak ölçüm yönteminin belirlenmesinin ardından en önemli adım kullanılacak uygun makine öğrenme algoritmasının seçilmesidir.

Rulmanlar için prognostik ve sağlık yönetimi amacıyla toplanan işlenmemiş veriler düşük genlikli, yüksek gürültülü olmakta ve anlamlı bir bilgi içermemektedir [39]. Bu nedenle, rulman arızalarıyla ilgili faydalı öznitelikleri çıkarmak için ölçüm sinyali üzerinde uygun sinyal işleme tekniklerinin uygulanması gereklidir. Araştırmacılar, rulmanlar için erken arıza tespit kabiliyetini geliştirmek amacıyla bir dizi sinyal işleme tekniği önermişlerdir. Bu tekniklerin çoğu frekans, zaman ve zaman-frekans alanı olan üç sınıftan birine girer.

Zaman domen analizi, temel olarak, elde edilen ham verilerin zamanın bir fonksiyonu olarak analiz edilmesini ifade eder. Rulman arızası özelliği çıkarımı için en yaygın yaklaşımdır. Bu

analiz sayesinde sağlıklı ve hatalı rulman arasındaki fark tespit edilebilir ancak hatanın tipi hakkında (iç bilezik veya dış bilezik gibi) bilgi elde edilemeyebilir. Rulman arızasının türünü belirlemek için frekans domeni analizi daha bilgilendirici ve uygundur [38].

Frekans domeni analizi, elde edilen sinyalin frekansın bir fonksiyonu olarak incelenmesine dayanır. Frekans domeni analizinin zaman domeni analizine göre avantajı, ilgilenilen belirli frekans bileşenlerini kolayca tanımlama ve izole etme yeteneğidir. En yaygın olarak kullanılan geleneksel analiz, hızlı fourier dönüşümü (FFT) aracılığıyla yapılan spektrum analizidir. Spektrum analizinin ana fikri, ya tüm spektruma bakmak ya da ilgilenilen belirli frekans bileşenlerine yakından bakmak ve böylece sinyalden öznitelikler çıkarmaktır [11].


Bölüm 2.3'te de belirtildiği gibi rulman bileşenlerinin dönme hızına bağlı ve teorik olarak hesaplanan rulman karakteristik hasar frekansları vardır. Bir arıza frekansına karşılık gelen titreşim enerjisi, ilgili bileşende oluşan arızanın seviyesine bağlı olarak artacaktır. Bu farklı arıza frekansları, rulman durumunun değerlendirilmesi için temel göstergeler olarak kullanılabilir. Bahsedilen frekanslar hız, geometri ve yatak tipinin bir fonksiyonudur. Bir sinyalin arıza bileşenlerinin tekrarlayan doğası, frekans spektrumundaki arıza frekanslarında yüksek genlikli tepe noktaları olarak açıkça gösterilebilir.

Frekans domeni analizi ile makine arızalarında yaygın olarak oluşan durağan olmayan (non-stationary), yani ortalama ve standart sapması zamanla değişen dalga biçimi sinyalleri işlenememektedir. Bu nedenle, durağan olmayan dalga biçimi sinyallerini hem zaman hem de frekans alanında inceleyen zaman-frekans analizi geliştirilmiştir. Zaman-frekans domeni teknikleri sinyal içindeki frekans bileşenlerinin zamana bağlı varyasyonlarını belirlemek için zaman ve frekans alanındaki sinyalleri birlikte analiz eder.

Rulman arıza tespiti amacıyla toplanan verilerin işlenmesi sırasında birtakım istatistiksel özelliklerden faydalanılmaktadır. Ham sinyallerden faydalı bilgilerin çıkarılması işlemi, öznitelik çıkarma olarak isimlendirilmektedir ve bu öznitelikler rulmanın sağlık durumunu karakterize etmelidir.

Rulmanlardan elde edilen ham ölçüm sinyallerinden öznitelik çıkarmak için hızlı fourier dönüşümü, zarf analizi, hilbert dönüşümü, dalgacık dönüşümleri, ampirik mod ayrıştırması ve bunların hibritleri gibi çeşitli sinyal işleme teknikleri kullanılmıştır. Kullanılan teknikler ve elde

edilen bazı öznitelikler Şekil 2.11’de verilmiştir. Bu sinyal işleme algoritmaları, zaman, frekans veya zaman-frekans düzleminde öznitelikler açısından bilgi elde etmek için kullanılır [38].



**Şekil 2.11:** Rulman diagnostik ve prognostik çalışmalarında yaygın olarak kullanılan öznitelikler ve öznitelik çıkarma yöntemleri [38].

İstenen özniteliklerin çıkarılmasının ardından sinyal analizi amacıyla birtakım algoritmalar kullanılmıştır. Bunlar arasında örnek olarak; fourier dönüşümü (FT) [40, 41], kısa zamanlı fourier dönüşümü (STFT) [42], dalgacık dönüşümü (WT) [43], ampirik mod ayrıştırması (EMD) [44], bispektrum [45], otoregresif (AR) frekans analizi [46], hilbert spektrum [47], anlık güç spektrumu [48], hilbert-huang dönüşümü (HHT) [49], nöral ağlar (NN) [50-52], saklı markov modeli (HMM) [53], bulanık mantık [54], destek vektör makineleri (SVM) [55], genetik algoritma [56, 57], kaba kümeler [58], otoregresif hareketli ortalama (ARMA) [59], stokastik model [60, 61], temel bileşenler analizi (PCA) [62] sayılabilir.

Yine rulmanlar üzerine yapılan diagnostik ve prognostik çalışmaları ile ilgili bazı örnekler aşağıdaki gibidir;

Caesarendra ve diğ. [63] ile Pandya ve diğ. [64] rulmanlarda bozulma eğrisini tahmin edebilmek için lojistik regresyon (LR) yöntemini kullanmışlardır. Ahmad ve diğ. [65] KFÖ tahmini için yine lojistik regresyon yöntemini kullanmışlardır.

Mahamad ve diğ. [66] ile Ben Ali ve diğ. [67] KFÖ tahmini için yapay sinir ağlarını (ANN) kullanmışlardır. Prieto ve diğ. [68], Ben Ali ve diğ. [69] ile Lei ve diğ. [70] de arıza teşhisi için

yapay sinir ağlarını kullanmışlardır. Saimurugan ve diğ. [71], Soualhi ve diğ. [72] ile Zhang ve diğ. [73] arıza teşhisi amacıyla destek vektör makinelerini (SVM) kullanmışlardır.

Son yıllarda derin öğrenme yöntemlerini kullanan çalışmalar da yapılmıştır. Bunlardan Liao ve diğ. [74] kısıtlanmış boltzmann makinesi (Restricted Boltzmann Machine) algoritmasını kullanarak KFÖ tahmini yapmaya çalışmıştır. Jia ve diğ. [75] ile Zhang ve diğ. [76] derin sinir ağları algoritması ile arızaları teşhis etmeye çalışmışlardır. Yine arıza teşhisi için Chen ve diğ. [77] DBN (Deep Belief Network) ve seyrek otomatik kodlayıcı yöntemini ve Shao ve diğ. [78] ise diagnostik amaçlı olarak EDAE (Toplu Derin Otomatik Kodlayıcılar - Ensemble Deep Auto-encoders) algoritmasını kullanmıştır.

KFÖ tahmini için Zhang ve diğ. [79] LSTM ve RNN (Uzun-kısa Süreli Hafıza - Long Short-term Memory / Tekrarlayan Sinir Ağı (Recurrent Neural Network) algoritmalarını, Shao ve diğ. [80] ise CNN (Evrişimli Sinir Ağı-Convolutional Neural Network) ve Uzun – LSTM algoritmalarını kullanmışlardır.

Rulmanların prognostik ve sağlık yönetimi ile ilgili lüteratürde yayınlanmış çeşitli derleme makaleleri de bulunmaktadır. Bu makalelerin temel odak alanları Tablo 2.1’de gösterilmiştir.

**Tablo 2.1:** Rulmanların prognostik ve sağlık yönetimi ile ilgili yayınlanan derleme makaleler [38].

| Yayın Yılı | Yazarlar             | İncelenen bileşen: Rulmanlar |    |    |         |    |    |      |    |    |            |    |    |         |    |    |      |    |    |
|------------|----------------------|------------------------------|----|----|---------|----|----|------|----|----|------------|----|----|---------|----|----|------|----|----|
|            |                      | Diagnostik                   |    |    |         |    |    |      |    |    | Prognostik |    |    |         |    |    |      |    |    |
|            |                      | Titreşim                     |    |    | Akustik |    |    | Akım |    |    | Titreşim   |    |    | Akustik |    |    | Akım |    |    |
|            |                      | SM                           | ML | DL | SM      | ML | DL | SM   | ML | DL | SM         | ML | DL | SM      | ML | DL | SM   | ML | DL |
| 1994       | Howard ve diğ. [14]  | ✓                            |    |    |         |    |    |      |    |    |            |    |    |         |    |    |      |    |    |
| 1999       | Tandon ve diğ. [15]  | ✓                            | ✓  |    | ✓       |    |    |      |    |    |            |    |    |         |    |    |      |    |    |
| 2006       | Jardine ve diğ. [16] | ✓                            | ✓  |    | ✓       |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2009       | Heng ve diğ. [17]    |                              |    |    |         |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2011       | Sikorsk ve diğ. [18] |                              |    |    |         |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2011       | Si ve diğ. [19]      |                              |    |    |         |    |    |      |    |    | ✓          |    |    |         |    |    |      |    |    |
| 2014       | Lee ve diğ. [20]     | ✓                            | ✓  |    | ✓       |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2015       | Kan ve diğ. [21]     |                              |    |    |         |    |    |      |    |    |            | ✓  |    |         |    |    |      |    |    |
| 2015       | Idriss ve diğ. [22]  |                              | ✓  |    | ✓       |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2015       | Henriq ve diğ. [23]  | ✓                            | ✓  |    | ✓       |    |    |      |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2016       | Wahyu ve diğ. [24]   |                              |    |    | ✓       | ✓  |    |      |    |    |            |    |    |         |    |    |      |    |    |
| 2016       | Rai ve diğ. [25]     | ✓                            | ✓  |    | ✓       |    |    | ✓    |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2018       | Ruonan ve diğ. [26]  |                              | ✓  |    |         |    |    |      |    |    |            |    |    |         |    |    |      |    |    |
| 2018       | Yaguo ve diğ. [27]   |                              |    |    |         |    |    |      |    |    | ✓          | ✓  |    |         | ✓  |    |      |    |    |
| 2018       | Mariela ve diğ. [28] | ✓                            | ✓  |    | ✓       |    |    | ✓    |    |    | ✓          | ✓  |    |         |    |    |      |    |    |
| 2021       | Singh ve diğ. [29]   |                              | ✓  | ✓  |         | ✓  | ✓  |      | ✓  |    |            | ✓  | ✓  |         | ✓  |    |      | ✓  |    |

SM - statistical methods (istatistiksel yöntemler)  
ML - machine learning (makine öğrenmesi yöntemleri)  
DL - deep learning (derin öğrenme)

### 3. MALZEME VE YÖNTEM

Bu tezin amacı asenkron motor rulman arızalarının teşhis edilmesi ve bozulma tespit edilen rulmanın kalan faydalı ömrünün tahmin edilebilmesi amacıyla bir kestirimci bakım modeli geliştirilmesidir. Bu kapsamda arıza teşhisinin yapılabilmesi amacıyla uygun sinyal işleme teknikleri kullanılarak diagnostik çalışması yapılmış ve ardından kalan faydalı ömrün tahmin edilebilmesi amacıyla prognostik bir model geliştirilmiştir.

#### 3.1. KULLANILAN VERİ SETİ VE ÖZELLİKLERİ

Çalışmada NASA'nın *Prognostics Center of Excellence* isimli web sayfasında yayınlanan veri setlerinden “Center for Intelligent Maintenance Systems (IMS), University of Cincinnati” ekibinin paylaştığı “Bearing Dataset” kullanılmıştır [81].


##### 3.1.1. Test Düzenegi

Laboratuvar ortamında gerçek ekipman ve sensörler kullanılarak elde edilen bu veri seti için 4 adet rulman bir şaft üzerine kurulmuş ve şaft bir AC motor üzerinden 2000 rpm hızında döndürülerek her rulman üzerinden titreşim verileri toplanmıştır. Şaft ve rulmanlara bir yay mekanizması ile 6000 lbs (~26.690N) bir radyal yük uygulanmıştır ve tüm rulmanlar yağlanmıştır. Veri toplama düzenegi Şekil 3.1’de gösterilmiştir. Veri toplama için National Instruments firmasının DAQ Card 6062E kartı kullanılmıştır. Testlerin başlama ve bitiş tarihleri, paylaşılan verilerin özellikleri ve oluşan arızalar bir sonraki bölümde verilmiştir.

Deneyde Rexnord firmasına ait ZA-2115 numaralı çift sıra rulmanlar kullanılmış ve PCB firmasına ait 353B33 model numaralı yüksek hassasiyetli Quartz ICP ivmeölçer kullanılmıştır. İvmeölçerler titreşim seviyesini “g” (g-kuvveti ya da yer çekimi de denir) cinsinden ölçmektedir ve  $1g=9,81m/s^2$  ‘dir. İvmeölçerin temel bazı teknik değerleri Tablo 3.1’de gösterildiği gibidir [82].

**Tablo 3.1:** Quartz ICP 353B33 İvmeölçer teknik özellikleri.

| Parametre                         | Değer                                          |
|-----------------------------------|------------------------------------------------|
| Hassasiyet ( $\pm 5\%$ )          | 100 mV/g ( 10.19 mV/(m/s <sup>2</sup> ))       |
| Ölçüm Aralığı                     | $\pm 50$ g pk ( $\pm 491$ m/s <sup>2</sup> pk) |
| Genişbant çözünürlük (1-10000 Hz) | 0.0005 g rms ( 0.005 m/s <sup>2</sup> rms)     |
| Frekans Aralığı ( $\pm 5\%$ )     | 1-4000 Hz                                      |
| Rezonans frekansı                 | $\geq 22$ kHz                                  |
| Algılama Elemanı                  | Quartz                                         |
| Ağırlık                           | 0.95 oz ( 27 g)                                |

**Şekil 3.1:** IMS rulman veri seti deney düzeneği.

Bu deney düzeneği belirtilen şartlar altında 3 tur çalıştırılmış ve her turda en az 1 rulman arızası meydana geldiğinde test sonlandırılmıştır. Bütün arızalar rulmanların tasarımsal ömrü aşıldıktan sonra meydana gelmiştir. Testler esnasında bozulmayı hızlandırıcı herhangi bir faktör uygulanmamış, rulmanların yük altında çalışırken ve normal çevre koşullarında doğal bozulma süreçleri izlenmiştir. Doğal yaşlanma davranışını gösteren bu tarz veriler diagnostik çalışmaları için de kullanılabilmekle birlikte prognostik modelleme için daha uygun ve tercih edilmektedir.


### 3.1.2. Veri Yapısı

Veri sahipleri tarafından her test için bir set olmak üzere toplam 3 veri seti paylaşılmıştır. Her veri seti sonunda bir rulman arızası oluşan arıza verisidir. Her veri seti kendi içinde 1 saniyelik titreşim ölçümü içeren ve belli aralıklarda kaydedilmiş bağımsız veri dosyalarını içermektedir. Bağımsız veri dosyaları 20kHz ile örneklenmiş 20.480 veri noktası içermektedir. Dosya isimleri verinin elde edildiği tarih ve saati göstermektedir. Tez çalışması kapsamında ilk iki veri seti kullanılmıştır. Veri sahipleri tarafından paylaşılan veri setlerinin diğer detayları Tablo 3.2’de gösterildiği gibidir.

**Tablo 3.2:** IMS rulman veri seti özellikleri.

|                            | Veri Seti-1                                                                                         | Veri Seti-2                                                                          |
|----------------------------|-----------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|
| <b>Kayıt zaman aralığı</b> | 22 Ekim (12:06) – 25 Kasım (23:39)                                                                  | 12 Şubat (10:32) – 19 Şubat (06:22)                                                  |
| <b>Dosya sayısı</b>        | 2156                                                                                                | 984                                                                                  |
| <b>Kanal sayısı</b>        | 8<br>(rulmanlara yatay ve dikey olmak üzere ikişer adet ivmeölçer takılmıştır)                      | 4<br>(rulmanlara birer adet ivmeölçer takılmıştır)                                   |
| <b>Kanal düzenlemesi</b>   | Rulman-1 (Kanal 1&2)<br>Rulman-2 (Kanal 3&4)<br>Rulman-3 (Kanal 5&6)<br>Rulman-4 (Kanal 7&8)        | Rulman-1 (Kanal 1)<br>Rulman-2 (Kanal 2)<br>Rulman-3 (Kanal 3)<br>Rulman-4 (Kanal 4) |
| <b>Dosya kayıt aralığı</b> | 10dk                                                                                                | 10dk                                                                                 |
| <b>Dosya formatı</b>       | ASCII                                                                                               | ASCII                                                                                |
| <b>Açıklama</b>            | Testin sonunda Rulman-3'te iç bilezik arızası ve Rulman-4'te yuvarlanma elemanı arızası oluşmuştur. | Testin sonunda Rulman-1'de dış bilezik arızası oluşmuştur.                           |

Testler sonucunda oluşan arızalar ise Şekil 3.2’de verilmiştir.



**Şekil 3.2:** NASA & IMS rulman veri setinde oluşan arızalar (a) iç bilezik hatası (b) yuvarlanma elemanı hatası (c) dış bilezik hatası.

### 3.1.3. Test Rulmanları

Test düzeneğinde kullanılan Rexnord marka ZA-2115 model nolu çift sıra rulmana ait görsel Şekil 3.3'te verilmiştir. Bu rulman için teknik veriler ise Tablo 3.3'te gösterildiği gibidir.



**Şekil 3.3:** Rexnord ZA-2115 rulman.

**Tablo 3.3:** Rulman karakteristik özellikleri.

| <b>Rexnord ZA-2115</b>               |            |         |
|--------------------------------------|------------|---------|
| Adım çapı                            | 2.815 inch | 71.5 mm |
| Yuvarlanma elemanı çapı              | 0.331 inch | 8.4 mm  |
| Her sırada yuvarlanma elemanı sayısı | 16         | 16      |
| Temas açısı                          | 15.17°     | 15.17°  |
| Statik yük                           | 6000 lbs   | 26690 N |


Bu teknik değerler kullanılarak, Bölüm 2.3'te denklemleri verilen rulman karakteristik hasar frekansları hesaplanmış ve sonuçlar Tablo 3.4'te verilmiştir.

**Tablo 3.4:** Rexnord ZA-2115 rulman karakteristik hasar frekansları.

| <b>Karakteristik Hasar Frekansları</b>  |                   |
|-----------------------------------------|-------------------|
| Şaft frekansı                           | 33.3 Hz           |
| Dış bilezik hasar frekansı (BPFO)       | 236 Hz            |
| İç bilezik hasar frekansı (BPFI)        | 297 Hz            |
| Yuvarlanma elemanı hasar frekansı (BSF) | 278 Hz (2x139 Hz) |
| Kafes arıza frekansı (FTF)              | 15 Hz             |


### 3.2. DİAGNOSTİK ÇALIŞMASI

Bu bölümde rulmanlarda oluşan arızaların teşhis edilebilmesi amacıyla kullanılan zarf analizi yöntemi açıklanmıştır. Bu analizde daha önce hesaplanan rulman teorik hasar frekansları kullanılmıştır. Kullanılan yöntemin blok şeması Şekil 3.4'te verilmiştir.

**Şekil 3.4:** Diagnostik model süreç adımları.

### 3.2.1. Zarf Analizi

Rulmanlarda iç bilezik, dış bilezik veya yuvarlanma elemanında çatlak, çukur veya parçalanma tarzı kusurların ortaya çıkması durumunda genel titreşim seviyesinde bir artış görülür. Yuvarlanma elemanı oluşan bu lokal hasarın her üstünden geçtiğinde kenardaki temas gerilimlerinde ani değişiklik oluşur. Bu durum Şekil 3.5'te gösterildiği gibi kısa süreli ancak yüksek seviyeli dürtüsel bir kuvvet oluşturur. Bu dürtüsel kuvvet, rulmanların yapısal rezonansını uyatarak kusur üzerinden geçen yuvarlanma elemanının frekansında yüksek frekans sönümlü salınımlar oluşturur [83].



Şekil 3.5: Dış bilezik arızası olan bir rulmana ait titreşim sinyali.


Sinyal işleme tekniklerinden olan zarf analizi ile arızalı rulmandan elde edilen titreşim sinyaline ait hasar frekansları çıkarılabilir ve oluşan hasarın tespiti yapılabilir. Zaman düzlemi analizinin geliştirilmiş hali olan zarf analizi, rezonans frekansı civarındaki yüksek frekansları geçiren bir filtre ile arıza kaynaklı titreşim frekans sinyallerini ayrıştıran bir metot olup yüksek frekans rezonans tekniği (HFRT – High Frequency Resonance Technique) olarak da bilinir.

Zarf analizinde uygulama Şekil 3.6'da gösterildiği gibi 3 adımdan oluşmaktadır [84].

- İlk aşamada sinyale bant geçiren filtre uygulanır. (Filtre frekans aralığının, dengesizlik, eksen kaçıklığı gibi diğer hata tipleri için değil, sadece rulman hatalarına yönelik olması için rezonans frekansı civarındaki yüksek frekansları geçirecek şekilde seçilmesi gerekmektedir.)

- Filtre uygulaması sonrasında elde edilen sinyale hilbert dönüşümü uygulanarak demodüle edilir. Elde edilen analitik sinyalin mutlak değeri alınarak zarf sinyali elde edilir. Bu şekilde sinyal doğrultulmuş ve düzleştirilmiş olur.
- Zarf uygulanan sinyallere hızlı fourier dönüşümü (FFT) uygulanarak zarf spektrumu elde edilir.

Sinyalde herhangi bir arıza durumu yoksa zarf spektrumu sadece gürültü içerecektir. Arıza olması durumunda ise hasar frekansları ve harmonikleri bulunacaktır. Arızanın seviyesine bağlı olarak tepe noktalarının genlik değeri artacaktır.



Şekil 3.6: Zarf analizi süreç adımları.

### 3.2.2. Hilbert Dönüşümü

Bir sinyal işleme yöntemi olan hilbert dönüşümü ile asenkron motorların farklı arızalarının tespiti yapılabilmektedir [85-87]. Düşük genlikli harmonikleri de tespit edebilmesi yöntemin üstün yönlerinden biridir. Bu sayede arıza tespiti daha kolay yapılabilmektedir.

Hilbert dönüşümü ile adaptif filtre çıkışından elde edilen filtrelenmiş  $x(t)$  sinyali negatif bileşenlerinden ayrıştırılır ve analitik çıkış sinyali  $z(t)$  elde edilir.  $x(t)$  sinyali için bu dönüşüm denklem 3.1’de verilmektedir [88,89].

$$H[x(t)] = \frac{1}{\pi} P \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (3.1)$$

Denklemden görülen  $P$  ifadesi Cauchy temel değerini belirtmektedir.  $t=\tau$  için bu eşitlik matematiksel olarak aşağıdaki gibi ifade edilebilir.

$$H[x(t)] = x(t) * \left(\frac{1}{\pi t}\right) \quad (3.2)$$


Konvolüsyon işlemi sonucunda yeni bir analitik sinyal olan  $z(t)$  elde edilir.  $z(t)$  sinyali kompleks düzlemde  $\alpha(t)$  uzunluğuna ve  $\theta(t)$  açısına sahiptir ve aşağıdaki gibi ifade edilebilir.

$$z(t) = \alpha(t)e^{j\theta(t)} \quad (3.3)$$

Verilen analitik sinyalin genliği ( $\alpha(t)$ ), faz açısı ( $\theta(t)$ ) ve açısal frekans ( $\omega(t)$ ) hesapları için denklem 3.4'te verilen eşitlikler kullanılabilir. Bu eşitliklerden  $\alpha(t)$  hasar frekanslarının genlik tespiti,  $\omega(t)$  harmonik bileşenlerin frekans tespiti için kullanılmaktadır.

$$\begin{aligned} \alpha(t) &= \sqrt{x^2(t) + \{H[x(t)]\}^2}, \\ \theta(t) &= \tan^{-1}\left(\frac{H[x(t)]}{x(t)}\right) \\ \omega(t) &= \frac{d\theta}{dt} \end{aligned} \quad (3.4)$$


Gerçek değerli bir sinyalin hilbert dönüşümü Şekil 3.7'de görüldüğü gibi büyüklüğü gerçek sinyalin zarfı olan yeni bir analitik sinyal oluşturur. Zarf sinyali üzerinde hızlı fourier dönüşümü uygulanarak zarfın spektrumu elde edilebilir ve elde edilen bilgi rulman arıza teşhisi için güvenilir bir bilgi kaynağı olarak kullanılabilir [84].



Şekil 3.7: Eksenel yüklü rulman sinyali: a) filtrelenmiş ve demodüle edilmiş, b) zarf güç spektrumu.

### 3.3. PROGNOSTİK MODELLEME

Bu bölümde tezin ana amacı olan kestirimci bakım modelinin tasarlanarak rulmanlarda arıza başlangıcı tespit edildikten sonra tam olarak bozulmasına ve kullanılamaz duruma gelmesine kadar geçen süreyi yani kalan faydalı ömrünü (RUL-Remaining Useful Life) tahmin etme süreci açıklanacaktır. Şekil 3.8’de sürecin temel adımları kullanılan teknikler ile birlikte gösterilmiş olup detaylar ilerleyen bölümlerde verilecektir.



Şekil 3.8: Prognostik model temel adımları.

### 3.3.1. Öznitelik Çıkarımı (Feature Extraction)

Öznitelik çıkarımı, ölçülen sinyallerin rulmanların sağlık durumunu karakterize edebilen farklı temsili büyüklükler olarak ifade edilmesi işlemidir. Bu anlamda ham sinyalden faydalı bilgi elde edilme işlemi olarak ta tanımlanabilir. Verilerden elde edilen özniteliklerin davranışı sistem bozuldukça tahmin edilebilir bir şekilde değişir.

Bilindiği gibi diagnostik temelde bir sınıflandırma problemidir ve prognostik ise gelecekteki sağlık durumunun tahmin edilmesi sürecidir. Diagnostik amacı ile kullanılacak özniteliklerin kalitesi izlenen ekipman verisi ile ilgili bileşen için arızalı veya sağlam ayrımını başarılı şekilde yapabilmesi ile ölçülür. Prognostikte, diagnostiğe ek olarak arızanın ilerlemesi modellenmeli ve tahmin yürütülmelidir. Bu nedenle diagnostike göre daha zor bir süreçtir.

Kestirimci bakım amacıyla tasarlanan bir prognostik modelinin başarısı büyük oranda seçilen özniteliklerin kalitesine bağlıdır. Öznitelik çıkarımı bütün prognostik yaklaşımlarında kullanılan ortak bir adımdır ve diagnostik ve prognostik süreçlerindeki en kritik adımlardan biridir [26].

Rulman hata sinyalleri ekipman üzerinden ölçülen toplam titreşim sinyallerine göre nispeten düşük genlikli kalmaktadır. Dolayısıyla rulman hataları ile ilgili faydalı bilgilerin çıkarılması için ölçüm sinyaline uygun sinyal işleme tekniklerinin uygulanması gerekmektedir. Araştırmacılar şimdiye kadar erken arıza teşhis yeteneğini artırmak amacıyla çeşitli sinyal işleme teknikleri önermişlerdir. Bunlar frekans, zaman ve zaman-frekans düzlemi olmak üzere üç kategori olarak ifade edilebilir [38].

Bu tez çalışmasında 1sn.'lik her ölçüm sinyali için aşağıdaki öznitelikler hesaplanarak analizde kullanılmıştır. Kullanılan bu özniteliklerin kısa açıklamaları ve hesaplama formülleri de ayrıca sunulmuştur.

- Zaman domeni öznitelikleri; etkin değer (rms), ortalama değer (mean), standart sapma (std), çarpıklık (skewness), basıklık (kurtosis), tepe-tepe değeri (peak to peak), tepe faktörü (crest factor), form faktör (shape factor), dürtü faktörü (impulse factor), marj faktörü (margin factor) ve enerji (energy),
- Spektral Kurtosis öznitelikleri: ortalama, standart sapma, çarpıklık, basıklık,
- Spektral Entropi öznitelikleri: ortalama, standart sapma, çarpıklık, basıklık,

- Ortalama frekans (mean frequency), medyan frekans (median frequency): Örnekleme frekansı cinsinden ortalama ve medyan frekans,
- Bant gücü (bandpower): Sinyalin ortalama gücü,
- BPFO ve BPFI hasar frekansı genlikleri.

#### **Etkin Değer (RMS-Root mean square):**

Karelerin ortalamasının karekökü anlamına gelen bu değer, değişen verinin büyüklüğü ölçen istatistiksel bir yöntemdir. Etkin değer denklem 3.5 ile hesaplanmaktadır.

$$\left( \frac{1}{N} \sum_{i=1}^N x_i^2 \right)^{\frac{1}{2}} \quad (3.5)$$

#### **Ortalama değer (Mean):**

Bir saykıldaki ani değerlerin ortalamasıdır ve denklem 3.6 ile hesaplanabilir.

$$\frac{1}{N} \sum_{i=1}^N x_i \quad (3.6)$$

#### **Standart sapma (Std):**

Standart sapma bir değişkenlik ölçüsüdür ve verilerin aritmetik ortalama etrafında ne ölçüde değiştiğini ifade etmektedir. Denklem 3.7 ile hesaplanabilir.

$$\sqrt{\sum_{i=1}^N \frac{(x_i - \bar{x})^2}{N - 1}} \quad (3.7)$$

#### **Tepe-tepe değeri (P-P):**

Sinyal genliğinin pozitif ve negatif tepe değerleri arasındaki farka denir ve denklem 3.8 ile hesaplanır.


$$x_{max} - x_{min} \quad (3.8)$$

### Çarpıklık (Skewness):

Verilerin ortalama değeri etrafındaki asimetrisinin bir ölçüsüdür. Çarpıklık negatifse, veriler ortalamanın daha çok soluna yayılır. Çarpıklık pozitifse, veriler daha çok sağa doğru yayılır. Normal dağılımın çarpıklık değeri sıfırdır. İstatistiksel olarak dağılımın üçüncü momenti olan çarpıklık denklem 3.9 ile hesaplanmaktadır.

$$\frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^3}{\sigma^3} \quad (3.9)$$

Pozitif ve negatif çarpıklık örnekleri ve bu örnekler için ortalama, mod ve medyan (ortanca) değerlerinin yerleşimi Şekil 3.9’da gösterilmiştir.



Şekil 3.9: Çarpıklık gösterimleri [90].


### Basıklık (Kurtosis):

Veri dağılımının normal dağılıma göre sivrilik veya basıklık seviyesinin ölçüsüdür [91]. Dağılımın genişliği ile ilgili yorum yapabilmek için kullanılan basıklık, dönen bileşenlerde arızaların gelişiminin hızlı bir göstergesi olarak bağımsız bir araç gibi kabul edildiğinden, rulmanların prognostik ve durum izlemesi için yaygın olarak uygulanmıştır.

İstatistiksel olarak dağılımın dördüncü momenti olan basıklık denklem 3.10 ile hesaplanabilmektedir.

$$\frac{1}{N} \sum_{i=1}^N \frac{(x_i - \bar{x})^4}{\sigma^4} \quad (3.10)$$

Normal dağılımın basıklık değeri 3'tür. Pozitif (basıklık >3) ve negatif (basıklık <3) basık dağılımların normal dağılıma göre görünüşleri Şekil-3.10'da gösterildiği gibidir.



Şekil 3.10: Basıklık gösterimleri [90].

#### Tepe faktörü (Crest Factor):

Tepe değerinin etkin değere oranını gösteren dalga biçimi ile ilgili bir parametredir [25]. Tepe faktörü, tepelerin bir dalga biçiminde ne kadar çok olduğunu gösterir. Örneğin tepe faktörü 1, kare dalga gibi tepe noktaları olmadığını gösterir. Denklem 3.11 ile hesaplanabilir.

$$\frac{\max|x_i|}{RMS} \quad (3.11)$$

#### Form faktör (Shape factor):

Etkin değerin sinyalin mutlak değerinin ortalamasına bölünmesi ile edilir. Form faktörü, sinyal boyutlarından bağımsız iken sinyal şekline bağlıdır. Denklem 3.12 ile hesaplanmaktadır.

$$\frac{RMS}{\frac{1}{N} \sum_{i=1}^N |x_i|} \quad (3.12)$$

**Dürtü faktörü (Impulse factor):**

Tepe değerinin sinyalin mutlak değerinin ortalamasına bölünmesi ile elde edilir. Denklem 3.13 ile hesaplanabilir.

$$\frac{\max|x_i|}{\frac{1}{N}\sum_{i=1}^N|x_i|} \quad (3.13)$$

**Marj faktörü (Margin faktör):**

Tepe değerinin sinyalin mutlak değer ortalamasının karesine bölünmesi ile elde edilir ve denklem 3.14 ile hesaplanabilir.

$$\frac{\max|x_i|}{\left(\frac{1}{N}\sum_{i=1}^N|x_i|^2\right)^{\frac{1}{2}}} \quad (3.14)$$

**Enerji (Energy):**

Sinyal işlemede, sürekli zaman sinyalinin enerjisi, sinyalin kare büyüklüğünün altındaki alan olarak tanımlanır ve ayrık zamanlı sinyalin enerjisi ise denklem 3.15 ile hesaplanır.

$$\sum_{i=1}^N x_i^2 \quad (3.15)$$

Frekans düzlemi özniteliklerinden olan ortalama frekans, medyan frekans ve bant gücü Matlab programının ilgili fonksiyonları ile hesaplanmıştır.

**Spektral basıklık:**

Spektral basıklık tekniği basıklık kavramını, bir sinyalin dürtüselliğinin nasıl olduğunu gösteren bir frekans fonksiyonuna genişletir. Diğer bir ifade ile spektral basıklık, basıklığın frekansla nasıl değiştiğini gösteren bir algoritmadır.

Spektral basıklık, titreşim sinyali analizi için kullanılan güçlü tekniklerden biridir ve son yıllarda dönen makinelerin arıza teşhisi ile ilgili çalışmalarda yoğun şekilde kullanılmıştır [91].

Elektromekanik sistemlerin durum izleme çalışmalarında titreşim sinyallerinin genelde dürtüsel davranış sergilediği görülür [92].

Sinyaldeki dürtüsellik farklı kaynaklı titreşim veya gürültü nedeniyle maskelenebileceği için ayrılması zor olabilir. Spektral basıklık metodu kurtogram yöntemini kullanarak işlenmemiş verinin içinde gömülü olarak bulunan demodüle edilmiş sinyali ayırmak için optimal frekans ve bant genişliğini bulmaya çalışır [93-95].

Bir  $x(t)$  sinyalinin spektral basıklığı  $K(f)$ , normalize edilmiş dördüncü dereceden spektral moment olarak tanımlanabilir ve kısa zaman fourier dönüşümü kullanılarak denklem 3.16 ile hesaplanabilir [96].

$$S(t,f) = \int_{-\infty}^{+\infty} x(t)w(t - \tau)e^{2\pi f t} dt \quad (3.16)$$

Burada  $S(t,f)$  sinyalin kısa zaman fourier dönüşümü,  $w(t)$  ise pencere (window) fonksiyonudur.

Spektral basıklık  $K(f)$  ise denklem 3.17 yardımı ile hesaplanır ve bu eşitlikte  $\langle . \rangle$  ifadesi zaman-ortalama operatörüdür.


$$K(f) = \frac{\langle |S(t,f)|^4 \rangle}{\langle |S(t,f)|^2 \rangle^2} - 2, \quad f \neq 0, \quad (3.17)$$

Bu tanımın önemli bir özelliği olarak durağan bir sürecin spektral basıklığı frekansın sabit bir fonksiyonudur [97].

Bu özellikleri ile spektral basıklık, gizli durağan olmayanların varlığını tespit edebilmekte, karakterize edebilmekte ve frekansta yerini tespit edebilmektedir. Ayrıca, yöntemin arkasındaki temel fikrin, sinyal geçici olduğunda ideal olarak yüksek değerleri alabilen ve sinyal durağan gaussian olduğunda ise sıfır olacak bir değer elde etmek olduğu anlaşılabılır [97].

Basıklığın frekans ile değişimini veren bir algoritma olan spektral basıklık, pencere uzunluğu seçiminden etkilenmektedir. Spektral basıklığın pencere uzunluğunu belirlemek için Antoni [96], çeşitli pencere uzunluklarını kısa zamanlı fourier dönüşümü (STFT) kullanarak hesaplamış ve basıklık değerinin maksimum olduğu frekans bandını seçmiştir.

Bu teknik, çeşitli merkez frekansı ve bant genişliğine sahip bir dizi filtre havuzu kullanılarak hesaplanan farklı basıklık değerlerinin bir diyagramda gösterildiği kurtogram tekniğidir. Bu tekniğin spektral basıklık hesaplama sürecinde uygulanması Şekil 3.11’de gösterildiği gibidir.



Şekil 3.11: KZFD ile spektral basıklığın hesaplanması.

### Spektral Entropi:

Entropi, belirsizlik veya düzensizlikle ilgili bir kavramdır. Bir sinyalin spektral entropisi, bilgi teorisindeki shannon entropisine dayanır ve dijital sinyallerin frekans düzlemindeki düzensizliğini veya karmaşıklığını ölçer [98].

Spektral güç dağılımının bir ölçüsü olan spektral entropi (SE), sinyalin frekans alanında normalize güç dağılımını bir olasılık dağılımı olarak ele alır ve bunun shannon entropisini hesaplar. Bu bağlamda shannon entropisi, sinyalin spektral entropisidir. Bu özellik, arıza tespiti ve teşhisinde öznitelik çıkarma için faydalı olabilir [99].

Spektral entropi konuşma tanıma [100] ve biyomedikal sinyal işleme [101] için de yaygın olarak kullanılan özniteliklerden biridir. SE denklem 3.18 ile hesaplanabilmektedir [102].

$$SE(F) = - \frac{1}{\log N_u \sum_u (P_u(F) \log_e P_u(F))} \quad (3.18)$$

$$SSH(F) = - \sum_u (P_h(F) \log_e P_h(F))$$

Burada  $P_u(F)$  spektral güç yoğunluğu fonksiyonunu,  $P_h(F)$  shannon entropi tahminini ( $SSH(F)$ ) ve  $N_u$  ise tüm frekansları ifade eder.

### BPFO ve BPFİ Genliklerinin Hesaplanması:

Veri setinde her bir ölçüm için BPFO ve BPFİ frekanslarına ait genlik değişimlerinin hesaplanması için Bölüm 3.2.1’de detayları anlatılan zarf analizi uygulanmıştır. Bu amaçla öncelikle ham sinyal için kurtogram tekniği ile bant geçiren filtre aralığı hesaplanmıştır. Ardından bu bant aralığında zarf spektrumu hesaplanarak BPFO ve BPFİ frekanslarına karşılık gelen genlik değerleri çıkarılmıştır. Hesaplama detayları Bölüm 4.2’de açıklanacaktır.

### 3.3.2. Dalgacık Dönüşümü (Wavelet Transform):


Analog sinyallerin işlenebilmesi için dijital hale getirilmelidir. Sürekli sinyallerin incelenebilmesi için belirli noktalardan alınan örneklerle sinyal sayısallaştırılır ve bu şekilde çeşitli analiz yöntemleriyle incelenebilir [103].

Dalgacık analizi, ayırık veya sürekli sinyal olarak gösterilebilen çeşitli fiziksel büyüklüklerin analizinde sıklıkla kullanılmaktadır. Dalgacık dönüşümü, işaretin zaman-frekans alanında analizi için kullanılan bir dönüşüm türüdür.

Dalgacık ismi verilen bir fonksiyon bu dönüşümün temelini oluşturur. KZFD’de olduğu gibi burada pencere görevini ana dalgacık yapar, fakat bu ana dalgacık, işlem boyunca ölçeklenir ve aynı zamanda ötelenir. Öteleme dalgacığın zaman ekseninde kaydırılması, ölçekleme ise dalgacığın daraltılıp genişletilmesi şeklinde yapılır [104].

Bilindiği gibi kısa zamanlı fourier dönüşümünde pencere genişliği sabit kalmaktadır. Dalgacık dönüşümünde ise genişlik sürekli değişir, böylece frekans ve zaman alanında çözünürlük artmış olur. Bu yönüyle dalgacık dönüşümü fourier dönüşümünden avantajlıdır. Şekil 3.12’de zaman-

ölçek alanını kullanan dalgacık analizi sonucunda sinyalde zaman ve ölçek değişimini göstermektedir [105].




**Şekil 3.12:** Dalgacık analizinde ölçek-zaman alanı.

Önceleri durağan olmayan sinyal analizinde daha çok KZFD kullanılmaktaydı. Ancak bu yöntemde pencere genişliği sabit ve dolayısıyla tüm sinyal için zaman çözünürlüğü de sabit kaldığı için işaretteki olası anlık frekans değişimleri yakalanamamaktadır [106].

Özetle; fourier dönüşümü frekansların ne zaman ortaya çıktığını değil sadece frekans değerini belirleyebilmektedir. KZFD’de sabit pencere fonksiyonu nedeni ile frekans-zaman çözünürlüğü sürekli aynıdır, değişmez. Dalgacık analizinde ise çözünürlük esnek bir şekilde ayarlanabilmektedir.

Şekil 3.13’te bahsedilen dönüşüm türleri için zaman-frekans alanında çözünürlükleri gösterilmiştir.



**Şekil 3.13:** Dönüşümler için zaman-frekans çözünürlüklerinin karşılaştırılması [180].


Bu özellikleri nedeniyle asenkron motor arızalarını teşhis etmek için dalgacık dönüşümü tekniğinin en uygun teknik olduğu araştırmacılar tarafından belirtilmiştir [107-113]. Bu sayede gelişmekte olan arızalar erken aşamada tespit edilebilmektedir.

Titreşim sinyalleri de doğal olarak durağan (stationary) değildir. Yani ortalama ve standart sapması zamanla sabit kalmaz, değişir. Bu nedenle zaman domen ve spektral kurtosis öznitelikleri için öznitelik çıkarımından önce sinyale durağan olmayan sinyallerin işlenmesinde sıklıkla kullanılan ayrık dalgacık dönüşümü uygulanmıştır.

### 3.3.2.1. Ayrık Dalgacık Dönüşümü (DWT)

Fourier dönüşümünde kullanılan pencere fonksiyonu yerine, burada ana dalgacık (mother wavelet) ismi verilen özel fonksiyonlar kullanılır. Genel kural olarak bu dalgacıkların ortalama değeri sıfırdır ve sınırlı bir süreleri vardır. Sonuç olarak dalgacık fonksiyonu pozitif ve negatif ekseninde salınım yaparak sonunda genlik değeri sıfıra ulaşır. Farklı kullanım amaçları ve özelliklere sahip ana dalgacıklar mevcuttur. Dalgacık ifadesi belirli bir uzunlukta pencere fonksiyonunu ifade edecek şekilde küçük dalga olarak ta ifade edilebilir.


Bu dönüşümde kullanılan bazı ana dalgacık fonksiyonları Şekil 3.14'te gösterildiği gibidir [105].



**Şekil 3.14:** Bazı ana dalgacık fonksiyonları.

Sürekli dalgacık analizi ve ayrık dalgacık analizi olarak iki şekilde yapılabilen dalgacık dönüşümünde en önemli faktörlerden biri ayrışmanın seviyesinin belirlenmesidir. Bu seviye normalde ham sinyalin örnekleme frekansı ile ayarlanmaktadır [114].

Ayrık dalgacık dönüşümü, zaman ölçekli dijital filtre kullanılarak gerçekleştirilir. Şekil 3.15'te basitçe bir sinyale uygulanan filtre ve çıkışı gösterilmiştir. S sinyaline uygulanan bir filtre ile sinyaldeki alçak ve yüksek frekanslar ayrıştırılmıştır. AGF düşük frekansları geçiren filtre, YGF ise yüksek frekansları geçiren filtre olarak adlandırılır.




**Şekil 3.15:** ADD filtre uygulaması.

Filtre sonucunda alçak geçiren filtrenin çıkışında oluşan ve A ile gösterilene yaklaşım (Approximation) ismi verilir. Detaylar (Detail) ise yüksek geçiren filtre çıkışında oluşan ve D ile gösterilen çıktılarıdır.

Ham sinyali temsil eden yaklaşım sinyalleri sinyalin tanımını verirken, detaylar sinyal ile ilgili karakteristik bilgileri içerir. Bu sinyaller orijinal sinyalin yarısı kadar örnek içermekte ve sinyalin alçak ve yüksek frekans bilgilerini ihtiva etmektedir.

Şekil 3.16’da herhangi bir sinyal için ayrıştırma işlemi sırasında farklı seviyelerde oluşan yaklaşım ve detaylar frekans bantları ile birlikte gösterilmiştir. A3 yaklaşımı orijinal sinyali temsil eder ve sinyalin tanımını verir. Sinyalin farklı frekans değerlerindeki yüksek frekans kısımlarını ise D1, D2, D3 detayları temsil etmektedir. Orijinal sinyalin elde edilmesi için A3 yaklaşımı ile tüm detayların toplanması yeterlidir. Bu işlem sonunda hangi frekans aralığında analiz yapılmak isteniyorsa o aralığa uygun yaklaşım veya detay bilgisi seçilerek ilerlenebilir.



**Şekil 3.16:** Yaklaşımlar detaylar ve frekans bantları arasındaki ilişki.


Tez çalışması kapsamında orijinal titreşim sinyallerine önce db5 (daubechies 5) ana dalgacığı kullanılarak gürültü giderme işlemi uygulanmıştır. Bu şekilde istenmeyen yüksek frekanslı gürültülerin giderilmesi hedeflenmiştir. Ardından aynı sinyale yine db5 ana dalgacığı kullanılarak 3 seviye ayrıştırma işlemi uygulanmıştır. Sonuçta elde edilen yaklaşım katsayıları kullanılarak zaman ve frekans domenindeki öznitelikler hesaplanmıştır. Literatürde farklı sinyal veya uygulamalar için farklı ana dalgacık tipleri kullanıldığı görülmüş olup sabit bir yöntem bulunmamaktadır. Araştırmacılar genelde farklı dalgacık tipleri ile analizlerini yapıp sonuçları karşılaştırarak karar vermektedirler. Bu çalışma kapsamında da farklı dalgacık tipleri ile analiz yapılmış olup en iyi tahmin performansının db5 dalgacığı ile elde edildiği

görülmüştür. Db5 ve diğer daubechies dalgacık tiplerinin dönen makine arıza teşhisinde yaygın şekilde kullanıldığı da bilinmektedir [181].

### 3.3.3. Öznitelik Seçimi

Çeşitli öznitelikler matematiksel olarak hesaplandıktan sonra veri işleme sürecinin devamında kullanılmak üzere bazılarının seçilmesi gerekmektedir. Bütün özniteliklerin aynı önem derecesine sahip olduğu varsayımı ile tamamının kullanımı işlem yükünü artıracak gibi sınıflandırma başarısını düşürebilir ve bazı özellikler arasında korelasyon olabileceğinden gereksiz de olabilir. Bu nedenle öznitelik seçimi prognostik ve sağlık yönetimi sürecindeki en önemli adımlardan biridir.

Literatürde temel bileşenler analizi (PCA) [115], ReliefF [116,117], genetik algoritma [118] gibi çeşitli öznitelik seçme algoritmaları kullanılmıştır. Öznitelik seçiminin temel amacı, arızayı temsil edebilecek minimum sayıda öznitelik seçilmesi ve rulmanın durumunun doğru bir şekilde tanımlanmasını sağlamaktır. Böylece tahmin sonucunun güvenilirliği ve çözümün kapsayıcılığı artmış olacaktır. Şekil 3.17’de öznitelik seçiminin, gereksiz olanların ortadan kaldırılması nedeniyle geleneksel algoritmaların sınıflandırma doğruluklarında önemli bir artışa neden olduğu gösterilmiştir [38].



**Şekil 3.17:** Farklı algoritmalar için eğitim ve test doğruluklarının karşılaştırılması a) öznitelik seçimi yapılmadan b) öznitelik seçimi yapılarak.

Prognostik modeli için kullanılacak sağlık göstergesinin (HI-Health Index) performansının, prognostik modellemenin karmaşıklığı ve tahmin doğruluğu üzerinde büyük etkisi vardır. Bu

nedenle, doğru prognostik için uygun göstergenin seçilmesi ön koşuldur. Birçok araştırmacı, bu göstergelerin değerlendirilmesi için çeşitli ölçütler önermiştir. Bunlardan biri de yaygın olarak kullanılan monotonluk derecesidir.

Normal şartlarda, makinelerin bozulma süreçleri geri döndürülemez ve arızalanmış bir bileşenin manuel onarım olmadan kendi kendine düzelmesi beklenmez. Geri dönüşü olmayan bozulma süreçleriyle örtüşmesi için uygun bir sağlık göstergesi, monoton artan veya azalan bir eğilime sahip olmalıdır. Bu özellik monotonluk olarak adlandırılır [119].

Prognostik amacı ile kullanılacak iyi bir öznitelik, tüm numuneler için monoton olarak azalan veya artan olmalıdır. Bozulma süresinin monotonik olarak ilerlemesi, bazı prognostik modeller için önemli bir varsayımdır. Bu varsayımın insan müdahalesi ve kendi kendini iyileştirme (self healing) yoluyla ihlal edilmesi durumunda bozulma sürecinin monoton olmaması nedeniyle yalnızca belirsizlik artmakla kalmaz aynı zamanda modelin başarısız olmasına da neden olur [120].

Matematiksel olarak, bir  $f$  fonksiyonu,  $x \leq y$  olacak şekilde bütün  $x$  ve  $y$  değerleri için  $f(x) \leq f(y)$  ise monoton artan ve  $f(x) \geq f(y)$  ise monoton azalan olarak isimlendirilir. Diğer bir ifade ile, belirli bir aralıkta, sürekli bir artış veya sürekli bir azalma eğilimi gösteren fonksiyon monoton bir fonksiyondur. Şekil 3.18’de grafiksel olarak örnekler verilmiştir [26].



**Şekil 3.18:** Monoton ve monoton olmayan fonksiyon örnekleri.

Hesaplanan öznitelikler arasından belli özniteliklerin seçilmesi için özniteliklerin monotonluk seviyeleri hesaplanarak bu değer en yüksek olan ilk beşi ilerleyen veri işleme süreçlerinde

kullanılacaktır. Toplam verinin bir kısmının elimizde olduğu varsayımı ile tüm arıza verisinin belli bir kısmı eğitim verisi olarak kabul edilmiş ve her öznitelik için monotonluk dereceleri bu oran için hesaplanmıştır. Monotonluk değeri denklem 3.19 ile hesaplanabilmektedir.

$$\text{Mon}(X) = \frac{1}{K-1} \left| \text{No of } \frac{d}{dx} > 0 - \text{No of } \frac{d}{dx} < 0 \right| \quad (3.19)$$

Burada  $X = \{x_k\}_{k=1:K}$  sağlık göstergesi ( $x_k, t_k$  anındaki SG değerini gösterir.)

K değeri gösterge için toplam veri sayısını,  $d/dx = x_{k+1} - x_k$  SG dizisindeki farkı gösterir.

No of  $d/dx > 0$  ve No of  $d/dx < 0$  sırasıyla pozitif ve negatif farkların sayısını temsil eder.

$\text{Mon}(X)$ , X'in pozitif ve negatif türevlerinin mutlak farkını ölçer. 0 ile 1 arasında değişen monotonluk değeri için daha yüksek bir puan, monotonlukta daha iyi bir performans anlamına gelir [119].

### 3.3.4. Öznitelik Birleştirme ve Sağlık Göstergesinin Elde Edilmesi

Ekipmanlarda zamanla oluşan çatlak uzunluğu veya aşınma alanı gibi hasarların derecesi, aşağıdaki nedenlerden dolayı genellikle doğrudan gözlemlenemez [119].

- Endüstriyel ekipmanların operasyonları sırasında sık sık durdurulmasına izin verilmez.
- Bazen ekipmanın durdurulmasına izin verilse de, başlangıç hasarları her zaman mikro ölçekte ve profesyonel enstrümanların yardımı olmadan ölçülmesi zordur.
- Rulman yataklarındaki yuvarlanma elemanı arızasının, tahribat olmadan gözlemlenmesi zordur. Makinelerin sağlık durumlarını gerçek zamanlı olarak tahmin etmek için, genellikle çalışan ekipmandan titreşim sinyalleri ve akustik emisyon sinyalleri gibi farklı türde durum izleme sinyalleri ölçülür. Ölçülen bu sinyaller, sağlık durumu ile ilgili bilgilerin yanında ölçüm gürültüsü de içerir. Bir önceki bölümde anlatıldığı gibi sinyallerin çeşitli özellikleri çıkarılarak bozulma süreci takip edilmeye çalışılır.

Uygun bir sağlık göstergesinin prognostik modellemeyi basitleştirmesi ve doğru tahmin sonuçları üretmesi beklenir.

Bir önceki bölümde belirtildiği gibi monotonluk derecesi en yüksek ilk beş öznitelik bundan sonraki veri işleme sürecinde dikkate alınacaktır. Burada beş adet olan öznitelik sayısı tamamen öznel olarak seçilmiştir. Farklı sayıda öznitelik veya monotonluk derecesi için belli limitler tanımlanarak o limiti geçenlerin hesaba katılması gibi yöntemler de denenerek performans test edilebilir ve nihai karar verilebilir. Tez çalışması kapsamında beş adet öznitelik seçiminin yeterli tahmin performansı sağladığı görülmüştür. Bu şekilde seçim yapıldıktan sonra bu özniteliklerin birleştirilerek rulman yaşlanmasını veya arıza oluşum sürecini temsil edecek tek bir indikatör elde edilmesi gerekmektedir. Bu indikatör sağlık göstergesi olarak (HI – Health Indicator) olarak isimlendirilmektedir.

#### **3.3.4.1. Temel Bileşenler Analizi (Principal Component Analysis)**

Sağlık göstergesinin elde edilmesi ile ilgili literatürde farklı yöntemler kullanılmıştır. İzlenen sinyallerin RMS, kurtosis değerleri veya zarf analizi ile elde edilen hasar frekans genlikleri kullanılan göstergelerden bazılarıdır. Bununla birlikte, boyut indirgeme tekniği olarak ta bilinen Temel Bileşenler Analizi (TBA) de sağlık göstergesi elde etmek için yaygın olarak kullanılan yöntemlerden birisidir.

Widodo ve arkadaşları [121], özellik setinin boyutunu azaltmak için TBA'ni kullanmış ve bilinmeyen durumlar ile sağlıklı durum arasındaki sapmaları bir sağlık göstergesi olarak hesaplamıştır. Benkedjough ve diğerleri [122] kesme takımları için bir HI oluşturmak adına izometrik özellik haritalama ile birlikte TBA'ni kullandı. Wang ve diğerleri [123] çok sayıda özniteliği birleştirmek için TBA kullandı ve T2 istatistiğini rulmanların sağlık göstergesi olarak hesapladı. TBA tabanlı sağlık göstergesi kullanan farklı çalışmalar da mevcuttur [124-127].

Temel Bileşenler Analizi, aralarında ilişki bulunan çok sayıda değişkenden oluşan bir kümeyi, büyük kümedeki bilgilerin çoğunu hala içerecek şekilde daha küçük ve aralarında ilişki bulunmayan değişkenlere dönüştüren bir boyut indirgeme tekniğidir. Boyuttaki bu azalma, bu veri kümesinin birbiriyle ilişkisiz temel bileşenler veya değişkenlerden (öznitelikler) oluşan yeni bir veri kümesine dönüştürülmesi ile elde edilir. TBA çok değişkenli bir analiz tekniğidir ve temel bileşenler yeni verilerin kovaryans matrisinin özvektörleridir. TBA, verilerdeki kalıpları bularak ve çok fazla bilgi kaybı olmadan boyutların sayısını azaltarak verileri analiz etmek için kullanılan güçlü bir araçtır. TBA, çok değişkenli veri analizi, görüntü sıkıştırma, yüz tanıma gibi birçok alanda kullanılmaktadır.

TBA çeşitli veri işleme süreçlerinde ara ve yardımcı bir yöntem olarak kullanılmaktadır. TBA ile orijinal kümede bulunan değişken sayısı kadar temel bileşen elde edilir ve bunların her biri, orijinal değişkenlerin doğrusal bir bileşimidir. Sonuç olarak, elde edilen bütün temel bileşenler tüm değişkenlerden belirli oranda bilgi içerir. Dolayısıyla çok boyutlu veri seti yerine, toplam değişkenliğin büyük kısmını açıklayan sayıda temel bileşen kullanılarak boyut indirilmesi sağlanabilmektedir. Kullanılan temel bileşen veya bileşenlerin dışında kalan temel bileşenler ise ihmal edilebilir [128]. Örnek olarak; 3 boyutlu insanlar, 2 boyutlu gölgeleri kullanılarak tanımlanabilir veya bilgi aktarılabilir.

Temel bileşen analizi sırası ile aşağıdaki işlemler uygulanarak yapılabilir [129]:

1. Veri ölçekleme,
2. Kovaryans matrisinin hesaplanması,
3. Özdeğer ve özvektörlerin hesaplanması,
4. Temel bileşenlerin hesaplanması,
5. Yeni veri setinin elde edilmesi.

Veri ölçekleme adımında her öz niteliğin (boyutun) ortalaması hesaplanarak elde edilen değer o boyuttan çıkarılır.

Kovaryans, boyutların birbirine göre ortalamadan ne kadar farklı olduğunu bulmak için kullanılan bir benzerlik ölçüsüdür ve denklem 3.20 ile hesaplanmaktadır.

$$Cov(X, Y) = \frac{1}{N-1} \sum_{i=1}^N (x_i - X')(y_i - Y') \quad (3.20)$$

Burada  $X'$  ve  $Y'$  sırasıyla  $X$  ve  $Y$  veri setlerinin ortalamasını,  $N$  ise veri sayısını ifade etmektedir.

$X$  ve  $Y$  arasındaki kovaryans pozitifse, ortalama olarak  $X$  artırıldıkça  $Y$  de artar. Kovaryans negatifse, ortalama olarak  $X$  artarken  $Y$  azalır.  $X$  ve  $Y$  arasındaki kovaryans sıfır ise,  $X$  ve  $Y$ 'nin birbirleriyle ilişkisizdir.

$n$  boyutlu bir veri seti için  $\frac{n!}{(n-2)*2}$  farklı kovaryans değeri hesaplanabilir.

Kovaryans matrisi farklı değişkenler arasındaki korelasyonu ifade eden bir kare matristir.  $n$  boyutlu bir veri seti için kovaryans matrisi  $n \times n$  ve matristeki her değer iki ayrı boyut arasındaki kovaryans değerini ifade eder. Kovaryans matrisi verinin hem varyansını hem de kovaryansını tanımlamaktadır ve temel özellikleri aşağıdaki gibi sıralanabilir. Kovaryans matrisi;


- Kare matristir.
- Simetrik bir matristir.  $cov(X,Y) = cov(Y,X)$
- Yarı pozitif tanımlı bir matristir.  $A \Sigma A^T \geq 0$

$d$  boyutlu bir veri setinin kovaryans matrisi 3.21 eşitliği ile ifade edilir.

$$\Sigma = \begin{bmatrix} var(x_1, x_1) & \cdots & cov(x_1, x_d) \\ \vdots & \ddots & \vdots \\ cov(x_d, x_1) & \cdots & var(x_d, x_d) \end{bmatrix} \quad (3.21)$$

Köşegen elemanlar, boyutların kendisiyle olan kovaryans değeridir.  $cov(X, X) = var(X, X)$  olduğundan olarak köşegen elemanlar için kovaryans yerine varyans yazılabilir.

TBA, temel bileşenleri belirlemek için kovaryans matrisinin özdeğer ayrıştırmasını kullanır. Özdeğer ve özvektörler çift olarak kullanılırlar ve her özvektöre karşılık gelen bir özdeğer bulunmaktadır.  $n \times n$  boyutlu bir kovaryans matrisi için  $n$  adet özvektör olacaktır. Özvektörler, veri kümesindeki varyansı (yayılımı) anlamak için kullanılır. Örneğin, hangi değişkende daha fazla varyans var ise özvektör bu yönün büyüklüğüne eşit olacaktır. Özdeğerleri azalan düzende sıralarsak, ilk özdeğer ile ilişkili özvektör bize birinci temel bileşeni (PC1) verir, ikinci özdeğer ile ilişkili ikinci özvektör bize ikinci temel bileşeni (PC2) verir ve süreç bu şekilde devam eder. İlk temel bileşen tüm değişkenliği en çok temsil eden bileşendir. İkincisi ise geri kalan kısmı en çok açıklayan bileşendir. Şekil 3.19'da üç boyutlu bir özellik verisinin TBA yöntemi ile iki boyutlu temel bileşen uzayında gösterimi açıklanmıştır.



**Şekil 3.19:** Temel bileşen analizi [130].

Özvektörlerin bazı özellikleri aşağıdaki gibidir;

- Kovaryans matrisinin özvektörleri her zaman birbirine diktir ve veriler bu ortogonal özvektörler cinsinden ifade edilir.
- Üzerlerinde doğrusal bir dönüşüm (başka bir vektörle çarpım) yapıldığında, yönleri değişmez.
- Vektörün uzunluğu ile değil sadece yönü ile ilgilenildiğinden, tüm özvektörlerin aynı uzunlukta olması için özvektör uzunluğu 1'e ayarlanır.
- Kovaryans matrisinin  $\sum$  özvektörü 3.22 denklemini sağlar.

$$\sum u = \lambda u \quad (3.22)$$

Burada  $u$  özvektörü,  $\lambda$  ise o özvektöre karşılık gelen özdeğeri ifade etmektedir.

Sonuncu adımda amaç, verileri orijinal eksenler yerine temel bileşenlerle temsil edebilmek için kovaryans matrisinin özvektörleri kullanılarak oluşturulan özellik vektörünü kullanmaktır. Bu hesaplama, özellik vektörünün devriği ile orijinal veri kümesinin devrini çarparak yapılabilir.

$$\text{Final Veri Seti} = \text{Özellik Vektörü} \times \text{Normalize Edilmiş Veri}$$

Bir önceki bölümde elde edilen beş öznitelik üzerinde TBA yöntemi ile boyut indirgeme (veya öznitelik birleştirme) uygulanmış olup en yüksek varyansı temsil eden ilk temel bileşen (PC1) sağlık indikatörü olarak seçilmiştir. Ayrıca elde edilen temel bileşenlerin monotonluk seviyelerine bakıldığında ilk temel bileşenin monotonluk derecesinin daha yüksek olduğu da

görülebilir. Literatürde prognostik amacı ile TBA yöntemini kullanan ve ilk temel bileşeni sağlık göstergesi olarak kabul eden farklı çalışmalar da mevcuttur [131].

#### 3.3.4.2. *Veri Yumuşatma*


Rulmanlarda oluşan arızaların geri döndürülemez olduğu kabul edilmektedir ve bu kabul sağlık göstergesinin trendini modellemeyi kolaylaştırmaktadır [132]. Ancak, elde edilen sağlık göstergesinde rastgele dalgalanma bölgeleri görülebilmektedir ve bu durum prognostik çalışması için sorun teşkil etmektedir [133].

Dalgalanma alanları çeşitli faktörlerden kaynaklanmaktadır. İlk olarak, her bir yuvarlanma elemanı farklı bir etkin yuvarlanma çapına sahiptir ve farklı bir hızda yuvarlanmaya çalışır, ancak kafes yuvarlanma elemanlarının ortalama konumlarından sapmasını sınırlar, böylece bir miktar rastgele kaymaya neden olur [134]. İkincisi, gürültüler ölçüm kalitesini bozar ve genellikle ilk düşük anomalilerin genliğinden daha büyüktürler. Ayrıca, nispeten zayıf rulman sinyalleri her zaman oldukça güçlü sinyallerden (dişliler vb.) etkilenir [135].

Önceki bölümlerde de bahsedildiği gibi ideal durum, rulman bozulmasını doğru bir şekilde karakterize eden monoton artan veya azalan bir özneliğe sahip olmaktır. Ancak endüstriyel ortamda durum böyle olmadığı gibi tork ve hız gibi değişken koşullar ile birlikte dalgalanma alanları da artar [133].

Araştırmacılar, sağlık göstergesi eğrisindeki küçük, rastgele dalgalanmaları ortadan kaldırmak ve gerçek bozulma davranışını ortaya çıkarmak için farklı yumuşatma ve eğri uydurma teknikleri kullanmışlardır [136-138].

Şekil 3.20’de arızalanan bir rulmanın RMS değerlerinde oluşan dalgalanmalar ve uygun şekilde düzeltilmesi gösterilmiştir.



Şekil 3.20: SG’de rastgele oluşan anomaliler veya suni dalgalanmaların düzeltilmesi.

Tez çalışmasında kullanılan IMS rulman veri setinde de birçok rulman için elde edilen sağlık göstergesine benzer şekilde artış azalış trendleri gözlenmektedir. Bazı araştırmacılar, rulmanlardaki kendi kendini iyileştirme olgusuna vurgu yaparak bunu açıklamaya çalışmışlardır [139,140].

Yaygın olarak kullanılan yumuşatma teknikleri, bu tür eğilimleri SG’den filtrelemez; bu teknikler daha çok SG’deki küçük, lokal dalgalanmaları azaltmak için kullanılır. Bu tez çalışmasında SG üzerindeki dalgalanmaları yok etmek ve rulmandaki uzun vadeli bozulma trendini elde edebilmek için LOESS yöntemi (Locally Estimated Scatterplot Smoothing) kullanılmıştır.


LOESS, parametrik olmayan bir teknik olarak bağımlı ve bağımsız değişkenler arasındaki ilişkileri belirler. Diğer istatistiksel testler için de güven aralıkları ile uygulanabilir [141, 142]. LOESS yönteminde her düzgünleştirilmiş değer, belirli bir aralıktaki komşu veri noktaları kullanılarak belirlenir. Aralıktaki her veri noktası için regresyon ağırlığı aşağıdaki denklem 3.23 kullanılarak hesaplanır.

$$w_i = \left( 1 - \left| \frac{x - x_i}{d(x)} \right|^3 \right)^3 \quad (3.23)$$

Burada  $x$ , yumuşatılacak değerle ilişkili tahmin değeridir,  $x_i$ , aralıktaki  $x$ 'in en yakın komşularını gösterir ve  $d(x)$ ,  $x$  ile aralıktaki en uzak tahmin değeri arasındaki yatay mesafeyi temsil eder.

LOESS daha sonra lokal ikinci dereceden regresyonu, ağırlıklı lineer en küçük kareler regresyonu olarak kullanır ve tahmin edici değerde ağırlıklı regresyon yoluyla düzleştirilmiş değeri belirler [132].

LOESS, verileri lokal regresyon ile belirlenmiş düzleştirilmiş değerlerle değiştirir. Şekil 3.21'de belli aralıktaki ( $x=2.5-3.0$ ) bir nokta için ( $x_i$ ) nasıl yumuşatılmış değer bulunduğu gösterilmiştir. Bu süreçte ilgili nokta ve bu noktadan belli mesafeye ( $\alpha$ ) kadar kısımdaki komşu noktalar kullanılmaktadır. Yayılma değeri olarak tanımlanan  $\alpha$ , eğri uydurma için kullanılan nokta sayısının toplam veri noktası sayısına oranı olarak tanımlanır ve bu değer 0-1 arasında değişir [143].



Şekil 3.21: LOESS yöntemi.


$\alpha$  değeri küçüldükçe pürüzlerin yeterince filtrelenemediği, büyüldükçe ise lokal eğriselliğin takip edilemediği görülebilmektedir. Amaca uygun olacak şekilde ortalama yüzeye yakın bir LOESS eğrisi oluşturmak için aşırı veya yetersiz uyumdan kaçınacak şekilde optimum bir  $\alpha$  değeri seçilmelidir [144].

Tez çalışması kapsamında uygulanan LOESS yönteminde en iyi performansı yakalamak amacıyla iki farklı veri seti için  $\alpha$  değeri 0,7 ve 0,9 olarak seçilmiştir. Sağlık göstergesi

değişiminin monotonik olması beklentisi ve ilerleyen süreçte üstel bozulma modeline giriş olarak uygulanacak nihai verinin model varsayımları ile uyumlu olması için dalgalanmaları büyük oranda giderecek ve uzun vadeli bozulma trendini ortaya çıkaracak şekilde yüksek bir  $\alpha$  değeri belirlenmiştir. Farklı değerlerin denenerek model performansının test edilmesi mümkündür.

### 3.3.3.3. Tahmin Başlama Noktasının Belirlenmesi

Üstel bozulma modeli, rulmanların KFÖ tahmini için en yaygın kullanılan yöntemlerden biridir. Ancak, üstel modeldeki eksikliklerden biri ilk tahminin başlayacağı noktanın belirlenmesinin öznel olarak yapılmasıdır [145]. Tahmin başlama noktası (TBN) konseptinin açıklanabilmesi amacıyla rulman bozulma sürecini tanımlayan basit bir gösterim Şekil 3.22’de gösterilmiştir. Burada Y ekseninde RMS değeri gösterilen “g” değeri (g-kuvveti) ivmeölçer tarafından ölçülen ivmelenme (hızlanma) değerini göstermektedir ve  $m/s^2$  cinsinden ifade edilebilir. X eksenine ise ölçüm aralıklarını gösteren zaman değişkenidir ve saniye cinsinden ifade edilebilir.



Şekil 3.22: Tahmin başlama noktasının gösterimi.

Rulmanın bozulma sürecinin genel olarak iki aşamadan oluştuğu görülmektedir. Birinci aşama rulmanın normal çalışma sürecini, ikinci aşama ise bozulma aşamasını temsil etmektedir. Görüldüğü üzere 1.aşamadaki bozulma indeksi (sağlık göstergesi) stabildir, bu da rulmanın sağlıklı olduğu anlamına gelir. Bir hata meydana geldiğinde, bozulma süreci, 1.aşamadan

2.aşamaya geçer. Burada bozulma indeksi, hasar ciddileştikçe genellikle katlanarak artar. 1.aşamadaki ana görev, sağlık durumunu izlemek ve yeni başlayan hataları tespit etmektir. Bir arıza tespit edildiğinde, tahmin süreci tetiklenir ve bu süreçte rulman için kalan faydalı ömür tahmin edilir. Tahmin etmeye başlama zamanı Şekil 3.22’de gösterildiği gibi TBN olarak tanımlanır. Üstel model için uygun bir TBN değeri seçmek önemlidir. Çünkü uygun olmayan bir nokta seçilirse, girişim gürültüleri tahmin sürecine dahil edilebilir veya kritik bilgiler tahmin sürecinden çıkarılabilir. Her iki durum da KFÖ tahmin doğruluğunu azaltabilir. Uygun TBN, arızanın meydana gelme zamanı olmalıdır, ancak bunu belirlemek zordur çünkü bir rulmanın başlangıç arızaları genellikle rastgele meydana gelir ve arıza karakteristiği oldukça zayıftır. Bu nedenle, üstel modeldeki TBN genellikle subjektif olarak seçilir, bu da üstel modelin uygulamalarını kısıtlar.

Literatürde TBN, mühendislik normu ISO 10816,  $\mu+3\sigma$  yaklaşımı [145-147] ve bir makinenin istatistiksel özelliklerine ve en uzun zaman sabitine dayalı teknikler [148,149] dahil olmak üzere farklı yöntemler kullanılarak belirlenmiştir.

Bu yaklaşımlar, çok sayıda ekipmanın istatistiksel özelliklerini kullanır ve TBN'yi belirledikten sonra bir alarm verir. Sistemlerin davranışı, farklı faktörlere bağlı olarak değişir ve bu yaklaşımlar, alarmı kalibre etmek için sistem davranışındaki değişikliklere uyum sağlamada başarısız olur. Sağlık göstergesindeki rastgele anormalliklerin veya sahte dalgalanmaların ele alınması da KFÖ tahmin performansı için kritik öneme sahiptir. Bu dalgalanmalar tanımlanmazsa, zayıf KFÖ tahminlerine neden olabilir [136].

Tez çalışması kapsamında TBN noktasının bulunması için standart sapmanın değişimi baz alınmış ve sağlık göstergesi üzerinde ani değişimin olduğu nokta TBN olarak kabul edilmiştir. Bu amaçla kullanılan Matlab programının ilgili fonksiyonu veri üzerinde değişim noktası bulmak için parametrik bir global yöntem kullanır. Fonksiyonda sırası ile;

- Bir nokta seçilerek veri iki bölüme ayrılır.
- Her bölüm için istenen istatistiksel özelliğin (burada standart sapma) ampirik bir tahmini hesaplanır.
- Bir bölüm içindeki her noktada, özelliğin ampirik tahminden ne kadar saptığı ölçülür, tüm noktalar için sapmalar eklenir.
- Toplam kalan hatayı bulmak için iki bölümün sapmaları toplanır.

- Toplam kalan hata minimuma ulaşana kadar bölme noktasının konumu değiştirilir.

$x_1, x_2, x_3, \dots, x_N$  şeklinde verilmiş bir sinyal için;  $\chi$  ampirik tahmin ve  $\Delta$  sapma değeri olmak üzere denklem 3.24 ile hesaplanan değer en küçük olacak şekilde değişim noktası tespit edilir.

$$J(k) = \sum_{i=1}^{k-1} \Delta(x_i; \chi([x_1 \dots x_{k-1}])) + \sum_{i=k}^N \Delta(x_i; \chi([x_k \dots x_N])) \quad (3.24)$$

Artık hatayı en aza indirmek, olabirlik kestirimini en üst düzeye çıkarmakla eşdeğerdir. Ortalama  $\mu$  ve varyans  $\sigma^2$  olan normal bir dağılım verildiğinde,  $N$  bağımsız gözlem için log olabirlik fonksiyonu 3.25 eşitliği ile verildiği gibidir:

$$\log \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}} = -\frac{N}{2} (\log 2\pi + \log \sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - \mu)^2. \quad (3.25)$$

İstatistiki değer olarak standart sapma seçilmişse ortalama sabitlenir ve fonksiyon 3.26 eşitliğini kullanır.

$$\begin{aligned} \sum_{i=m}^n \Delta(x_i; \chi([x_m \dots x_n])) &= (n - m + 1) \log \sum_{i=m}^n \sigma^2([x_m \dots x_n]) \\ &= (n - m + 1) \log \left( \frac{1}{n - m + 1} \sum_{i=m}^n (x_i - \text{mean}([x_m \dots x_n]))^2 \right) \\ &= (n - m + 1) \log \text{var}([x_m \dots x_n]). \end{aligned} \quad (3.26)$$

### 3.3.4.3. Arıza Eşiğinin Belirlenmesi

Tez çalışması kapsamında bir sonraki adımda rulmanın kalan faydalı ömrünü tahmin etmek için üstel bozulma modeli kullanılacaktır. Bu model çoğunlukla ekipman ya da bileşen kümülatif bir bozulma yaşadığında kullanılır. Bu tarz bozulma süreci herhangi bir mekanik sistem için geçerli kabul edilebilecek bir süreçtir. Üstel bozulma modeli, veri işleme süreçlerinden sonra elde edilen nihai sağlık göstergesine uygulanır. Bu bozulma modeli, sağlık göstergesinin önceden tanımlanmış bir eşik değerini geçtiği gelecekteki bir zaman adımını tahmin etmek için kullanılır. Bu gelecek zaman adımı ile şimdiki zaman adımı arasındaki fark ta kalan faydalı

ömür bilgisini verir. Bu arıza eşiği genellikle önceki arıza geçmişine göre tanımlanır veya sağlık göstergesi üzerinde arızalı bölgeden önce güvenli bir değer olarak seçilir [150].

Uygun arıza eşiğini belirlemek, KFÖ tahmin algoritmasının ne zaman duracağını ve tahmini KFÖ değerini çıkarması gerektiğini belirlediğinden zorlu ve önemli bir aşamadır. Genel olarak, bu tür arıza eşikleri her zaman açıkça tanımlanmaz ve belirli bir uygulama için arıza eşiğini tanımlamak, endüstriyel standartlar, uygulama hassasiyeti ve ilgili mühendislik alanında bilgi gerektirir [151].

Literatürde; rulmanın farklı bozulma süreçlerini adaptif olarak çıkaran, çıkarım temelli bir yöntem [147], arıza eşiği olarak sabit bir titreşim değerini kullanan yöntemler [145,146], belli sayıda rulmanın arıza eşiklerinin ortalamasını alarak statik arıza eşiği elde eden yöntemler [153,154] ve ileri seviyede bozulmuş bir rulmanın sağlık göstergesi değerlerinin bir kümesini kullanarak arıza eşiğini belirleyen kümeleme tabanlı yöntemler [152] kullanılmıştır.

Arıza eşiği belirleme için yaygın olarak kullanılan yöntemler, ISO 7919 ve ISO 10816 serisi gibi bazı ISO standartlarına veya örneğin rüzgar türbinleri için VDI 3834 gibi belirli endüstriler için özel olarak tasarlanmış standartlara dayanmaktadır. Bu standartlar yalnızca RMS ve titreşim sinyallerinin tepe noktaları gibi bazı fiziksel sağlık göstergeleri için arıza eşiğini belirler. Ancak yeni türetilmiş ve RMS, kurtosis gibi kesin fiziksel anlamları olmayan bir sağlık göstergesi için arıza eşiği belirleme adına bir standart bulunmamaktadır [139].

Javed ve diğ. [155] PCA gibi fiziksel olmayan sağlık göstergeleri ile ilgili daha fazla araştırmaya ilham verebilecek yeni bir dinamik arıza eşiği belirleme konusunda yeni fikirler sağlamıştır.

Bu tez çalışmasında ise veri kümesi için geçmiş veri bulunmamaktadır. Bununla birlikte, yapılan deneysel çalışmada rulmanlarda arıza olduğu anda sistem durdurularak veri toplama süreci sonra erdirildiğinden dolayı, hata eşiği sabit ve SG'nin son değeri olarak seçilmiştir.

### 3.3.5 Üstel Bozulma Modeli

Birkaç bileşenli karmaşık makinelerde, sağlık bozulma analizi için fizik tabanlı modeller oluşturmak zordur. Birçok veriye dayalı yaklaşım, örneğin üstel bozulma [156-160] gibi bir

bozulma eğilimi varsayımını kullanır. Bu varsayım özellikle bir makinenin sağlığına ilişkin açık ölçülebilir bir parametrenin olmadığı durumlarda yararlıdır [161].

Bununla birlikte, rulman bozulma sinyallerinin doğal bir üstel büyümeye sahip olduğu bilinen bir durumdur ve önceden herhangi bir bozulma olmadığı bilinen durumlar için kullanımı önerilir. Bozulmuş sistemlerde çalışma ve çevre koşulları, sistem sağlığını yeni sistemlere göre daha fazla etkilediğinden, üstel model gerçek bozulmayı daha iyi temsil etmektedir [156].

Bu nedenle üstel model, rulman ömrünü modellemek için en yaygın kullanılan modeller arasındadır [162]. Sonuç olarak, her bir rulmanın bozulma eğrisi (elde edilen nihai sağlık göstergesi), en iyi  $\alpha e^{\beta t}$  üstel formuna uydurulur ve  $\alpha$  ve  $\beta$  üstel parametrelerini türetmek için kullanılır. Bu parametreler daha sonra rulman için kalan faydalı ömür hesabında kullanılacaktır [163].

Model tabanlı yöntemler, bir makinenin bozulma sürecini tanımlamak için matematiksel veya fiziksel modeller kurarlar ve ölçülen verileri kullanarak model parametrelerini tahmin ederler. Liao ve diğ. [164], yuvarlanan eleman yataklarının KFÖ'nü tahmin etmek için orantılı tehlike ve lojistik regresyon modellerine dayanan bir tahmin yöntemi önermiştir. Tian ve diğ. [165], rulmanlardan oluşan sistemlerin KFÖ tahmini için orantılı tehlike modeline dayalı bir yöntem önermiştir. Liao [166] yine rulman KFÖ tahmini için bir genetik programlama yöntemiyle birleştirilmiş Paris modelini kullanmıştır. Modele dayalı yöntemler, hem uzman bilgisini hem de ölçülen bilgiyi kullanabilir ve sonuç olarak rulmanların KFÖ tahmininde iyi çalışabilirler [145].

Tüm model tabanlı çalışmalar arasında en popüler yöntemlerden biri olan üstel model ilk olarak Gebraeel ve diğ. [151] tarafından kurulmuştur ve bu yöntemde model parametreleri, ölçülen bilgileri hesaba katmak için Bayes yaklaşımı kullanılarak güncellenir. Bu ilk çalışmadan sonra, KFÖ tahmini ve sağlık yönetiminde üstel modelin birçok varyantı ve uygulaması rapor edilmiştir [167-170]. Gebraeel [167] durum izleme yoluyla elde edilen çoklu geçmiş bozulma sinyallerini kullanarak model parametrelerini güncellemiş ve modeli daha da geliştirmiştir. Si ve diğ. [170] parametre tahmini için Bayes güncellemesini beklenti maksimizasyonu (EM) algoritması ile birleştirerek kapalı form bir KFÖ dağılımı sunmuştur. Bu çalışmalardan, üstel modelin, üstel benzeri bozulma süreçlerine sahip sistemlerin KFÖ tahmini için iyi çalıştığı görülebilir [145].

Üstel bozulma modeli, kısmi bozulmuş bileşenlerin mevcut ve gelecekteki bozulma durumları hakkında popülasyona özgü bozulma ve gerçek zamanlı sensör ölçüm verilerini birleştirerek kapsamlı bir değerlendirme sağlar. Bu amaca ulaşmak için ortak dağıtılmış rastgele katsayılara sahip bir parametrik bozulma modeli geliştirilmiştir. Bu prognostik metodolojisi özellikle bozulmanın kümülatif bir şekilde gerçekleştiği ve bozulma sinyalinin üstel bir fonksiyonel formla yaklaşık olarak tahmin edilebildiği durumlar için faydalıdır. Bu metodolojiyi uygulamak için aşağıdaki adımlar tamamlanmalıdır [167]:


- Bozulma sürecinin evrimi ile ilişkili fiziksel olayları tanımlamak (aşınma, parçalanma gibi),
- Bu olayı izlemek için uygun durum izleme teknolojisinin seçilmesi (ivmeölçer gibi),
- Bozulma sinyalinin geliştirilmesine yardımcı olmak için sensör verilerinde karakteristik bir desen tanımlanması (üstel büyüme gibi),
- Bozulma sinyali ile ilişkili bir arıza eşliğinin tanımlanması.

Bu prognostik metodolojinin uygulanmasındaki ilk adım, üstel modelin stokastik parametrelerine ilişkin önsel bilgileri elde etmektir. Bunun için bazı örnek bozulma sinyallerine üstel fonksiyonlu bir form uydurulması ve üstel parametre değerlerinin not edilmesi veya sübjektif olarak seçilmiş bir önsel dağılım kullanılması gerekebilir.

İkinci adımda sensör verileri elde edilerek başlangıç olarak kabul edilen önceki (ilk) dağılımın güncellenmesine başlanır. Güncelleme sıklığı, sonraki dağılımları hesaplamak için hangi eşitliklerin kullanılacağını belirleyecektir.

Sonuç olarak, izlenen bileşenin bozulma durumu ve bu durumun gelecekte muhtemelen nasıl gelişeceğini karakterize eden kapsamlı bir bozulma modeli elde edilmiş olur [167].

Bundan sonraki aşamada elde edilen sağlık göstergesi, üstel bozulma modelinin girdisi olarak kullanılacaktır. Üstel bozulma modelinin sensör verileri ile güncellenerek çalışma şekli Şekil 3.23'te gösterilmiştir.



Şekil 3.23: Üstel bozulma modeli.

Üstel bozulma modeli 3.27 denklemi ile ifade edilebilir.

$$h(t) = \Phi + \theta(t) \exp(\beta(t)t + \varepsilon(t) - \frac{\sigma^2}{2}) \quad (3.27)$$

Burada;

$h(t)$  zamanın bir fonksiyonu olarak sağlık göstergesini,  $\Phi$  ise modelin kesme noktasını (sabit bir değer) ifade etmektedir.

$\theta(t)$ , ortalaması  $\Theta$  ve varyansı  $\Theta$  olan bir lognormal dağılım olarak modellenen rastgele bir değişkendir.

$\beta(t)$ , ortalaması  $\beta$  ve varyansı  $\beta$  olan bir Gauss dağılımı olarak modellenen rastgele bir değişkendir.

$\theta$  ve  $\beta$  modelin eğimini belirlemektedirler. Her bir  $t$  adımı,  $\theta$  ve  $\beta$  dağılımı,  $h(t)$ 'nin en son değerine göre güncellenir.

$\varepsilon(t)$  modele eklenen gürültü bileşenidir. Ortalaması sıfır ve varyansı *NoiseVariance* olan bir normal bir dağılım olarak modellenmiştir.

$\sigma^2$  ise *NoiseVariance* değerine eşittir.

Eşitlikteki  $\frac{\sigma^2}{2}$  terimi ile 3.28 eşitliği sağlanmış olur.

$$E[h(t) | \theta, \beta] = \Phi + \theta \exp(\beta t) \quad (3.28)$$

Model parametrelerinin normalde eldeki geçmiş arıza verilerinden elde edilmesi beklenir. Ancak elimizde böyle bir veri ve parametre bulunmadığından ilk veri seti için bu değerler keyfi olarak ve yüksek varyanslı olacak şekilde aşağıdaki gibi seçilmiştir. Bu şekilde model büyük oranda  $h(t)$  sağlık göstergesinin gözlenen değerlerine dayanmaktadır.

Theta = 1, ThetaVariance =  $10^6$ ,

Beta = 1, BetaVariance =  $10^6$ ,

Phi = -1,

Ayrıca üstel bozulma modeli eğimin önemini değerlendirmek için de bir işlevsellik sağlar. Sağlık göstergesinde önemli bir eğim tespit edildiğinde, model önceki gözlemleri unutarak ve orijinal önceliklere dayalı olarak tahmini yeniden başlatacaktır. Algılama algoritmasının hassasiyeti, model parametrelerinden ayarlanabilmektedir. Ancak modelin girişinde kullanılacak sağlık göstergesi üzerinde yapılan veri işleme adımları sonrası zaten arıza başlangıç noktası tespit edilmiş ve öncesi veriden çıkarılmış olduğu için yeniden eğim detekte etme ihtiyacı bulunmadığından bu parametre boş bırakılmıştır. Bu durumda model ilk veriden itibaren tahmin sürecini başlatmaktadır.

Modelde sağlık göstergesinin değişimi ile gürültünün değişimi arasındaki ilişki 3.29 eşitliği ile türetilmiştir:

$$\Delta h(t) \approx (h(t) - \phi) \Delta \varepsilon(t) \quad (3.29)$$

Burada gürültünün standart sapmasının, eşiğe yakın olduğunda sağlık göstergesinde %10'luk bir değişime neden olduğu varsayılır. Bu nedenle gürültünün standart sapması denklem 3.30'daki gibi gösterilebilir.

$$\frac{10\% * Arıza eşiği}{Arıza eşiği - \Phi} \quad (3.30)$$

Sonuç olarak, NoiseVariance parametresi 3.31 eşitliği ile hesaplanıp modelde kullanılabilir.

$$\left( \frac{0.1 * Eşik değeri}{Eşik değeri + 1} \right)^2 \quad (3.31)$$

### 3.3.6 Performans Değerlendirme

Tanım olarak prognostik, kritik sistemlerde önceden uyarılar yoluyla yıkıcı arızalardan kaçınmayı amaçlar. Bununla birlikte, çevre ve çalışma şartları ile ilgili doğal belirsizlikler, modelleme hataları, veri gürültüsü ve gözlemci hataları gibi unsurlar başarıyı zorlaştıran faktörlerdir. Bu durum, prognostik metodlarının kritik uygulamalar için kullanılmadan önce performans değerlendirmesi yoluyla doğrulanmasını zorunlu hale getirmektedir.

Prognostik amaçlı yapılan çalışmalarda elde edilen performansın değerlendirilmesi için literatürde çeşitli metrikler tanımlanmıştır. Bu konuda standart bir tanım ya da yöntem olmamakla birlikte araştırmacılar kolaylık ve kendi ihtiyaçlarına uygunluk durumuna göre farklı metrikler kullanmışlardır. Bu standart eksikliği kısmen, farklı uygulamalar için farklı son kullanıcı gereksinimleri, değişken zaman ölçekleri, eldeki mevcut bilgiler, farklı alan dinamikleri vb. nedenlerden kaynaklanmaktadır [171].

Metrikler, araştırmacıların ve kullanıcıların bulgularını iletebilecekleri ve sonuçları karşılaştırabilecekleri standartlaştırılmış bir dil olarak değerlendirilebilir. Böylece bilimsel bilgilerin yayılmasına ve karar vermeye de yardımcı olur.

Saxena ve diğ. [172]'ne göre yaygın olarak kullanılan metrikler, MSE (mean squared error – ortalama karesel hata), MAPE (mean absolute percentage error – ortalama mutlak yüzdesel hata) gibi doğruluk ve hassasiyet metrikleridir.

Literatürde performansın farklı yönlerini ölçen daha fazla varyasyon ve modifikasyon bulunmaktadır. Bunlar arasında Yang ve diğ. [173] tarafından önerilen RMSE (root mean squared error – kök ortalama kare hatası) ve CI (confidence interval – güven aralığı) gibi metrikler sayılabilir.

Bu metrikler KFÖ dağılımındaki değişkenliğin istatistiksel olarak değerlendirmesini yapar. Bu bilgiler anlamlı olmakla birlikte, bu metrikler, daha fazla veri elde edildikçe KFÖ bilgisinin sürekli olarak güncellendiği uygulamalar için tasarlanmamıştır. Prognostik tahmin performansı (örneğin, doğruluk ve kesinlik), zaman geçtikçe ve ekipman ömrünün sonuna yaklaştıkça daha kritik olma eğilimindedir. Bu nedenlerle literatürde tahmin ufku (prediction horizon),  $\alpha$ - $\lambda$  doğruluğu, bağıl doğruluk (RA - relative accuracy), kümülatif bağıl doğruluk (CRA - cumulative relative accuracy) ve yakınsama gibi çeşitli metrikler geliştirilmiştir [171].

Bu tez çalışması kapsamında  $\alpha$ - $\lambda$  doğruluğu ve CRA (kümülatif bağıl doğruluk) metrikleri kullanılarak tahmin performansı değerlendirilmiştir.

### 3.3.6.1. $\alpha$ - $\lambda$ Doğruluğu ( $\alpha$ - $\lambda$ Grafiği)

$\alpha$ - $\lambda$  performansı, algoritmanın belirli bir uygulama için önemli olabilecek herhangi bir zaman aralığında ( $\lambda$  parametresi ile belirlenir) gerçek KFÖ'nün istenen hata marjları ( $\alpha$  parametresi ile belirlenir) dahilinde çalışıp çalışmadığını belirlemek için kullanılır. Bu metriğe göre, bir sistem ömrünün sonuna yaklaşırken hata marjı yakınsayan bir koni içinde kalmalıdır. Dolayısıyla bu metrik,  $\alpha$  ile belirlenen performans ölçüsüne göre tahminin belirli zamanlarda belirli limitler dahilinde olup olmadığını belirleyerek tahmin kalitesini ölçer. Bu zaman aralığı, sistemin toplam arızalanma ömrünün yüzdesi olarak belirtilebilir.

$\alpha$ - $\lambda$  doğruluğu ikili metrik olarak 3.32 eşitliği ile ifade edilebilir.

$$\alpha\text{-}\lambda \text{ doğruluğu} = \begin{cases} 1, & \pi(p(l_{t_\lambda}))|_{-\alpha}^{+\alpha} \geq \beta \text{ ise} \\ 0, & \text{diğer durumda} \end{cases} \quad (3.32)$$


Burada;

$\lambda$ ,  $t_\lambda = t_{\text{FPT}} + \lambda(t_{\text{EOL}} - t_{\text{FPT}})$  olacak şekilde zaman penceresi değiştiricisi,

$\pi(p(l_{t_\lambda}))|_{-\alpha}^{+\alpha} \geq \beta$  ise  $\alpha$ -sınırları içindeki olasılık yoğunluk fonksiyonunun (PDF) olasılık kütlesi anlamına gelir.

Örnek olarak  $\alpha=0.1$  ve  $\lambda=0.5$  alındığında bu metrik, tahmin sonucunun,  $t_{FPT} + 0.5(t_{EOL} - t_{FPT})$  olan tahmin süresinin yarısında gerçek KFÖ değerinin  $\pm\%10$  aralığına düşüp düşmediğini ölçer. Çıktı 1 ise, istenen tahmin doğruluğunun belirli bir zamanda karşılandığı anlamına gelir [139].

$\alpha$ - $\lambda$  doğruluğu, tahmin ufku (PH) gibi metriklere kıyasla daha katı bir gerekliliktir çünkü tahminlerin bir doğruluk konisi içinde, Şekil 3.24'te gösterildiği gibi zaman geçtikçe küçülen sınırlar içinde kalmasını gerektirir [171].



Şekil 3.24:  $\alpha$ - $\lambda$  doğruluk grafiği ve zaman içinde doğruluk konisinin daralması.

$\alpha$ - $\lambda$  performans metriği ile tahmin performansının zaman içerisindeki değişimi görsel olarak değerlendirilebilmektedir. Bu sayede herhangi bir  $t$  anındaki tahminin kabul limitleri içinde kalıp kalmadığı anlaşılabilmektedir. Buradaki  $\alpha$  değeri hesaplanan bir değer olmayıp arzu edilen ya da ihtiyaç duyulan tolerans değerini ifade etmektedir. Rulmanlar için bu değer farklı çalışmalarda %30 olarak alınmıştır [154].

Tez çalışması kapsamında da  $\alpha$  değeri 0.3 (%30) alınarak performans değerlendirmesi yapılmıştır.

### 3.3.6.2. Kümülatif Bağlı Doğruluk (CRA)

Kümülatif bağlı doğruluk, belirli zaman örneklerindeki bağlı doğrulukların normalleştirilmiş toplamını ifade eder [156].


Bağlı doğruluk (RA), belirli bir zaman indeksi  $i_\lambda$  için gerçek RUL  $r^*(i_\lambda)$ 'ya göre RUL tahminindeki ölçüm hatası olarak tanımlanır ve 3.33 eşitliği ile ifade edilir.

$$RA_\lambda = 1 - \frac{|l_{t_\lambda}^* - l_{t_\lambda}|}{l_{t_\lambda}^*} \quad (3.33)$$

Burada;

$l_{t_\lambda}^*$  ve  $l_{t_\lambda}$ ,  $t_\lambda$  noktası için  $t_\lambda = t_{FPT} + \lambda(t_{EOL} - t_{FPT})$  olacak şekilde, sırasıyla gerçek ve tahmin edilen KFÖ değerleridir. Bu eşitlik kullanılarak tahmin olasılık dağılımından uygun bir merkezi eğilim noktası tahmini elde edilir.

$\alpha$ - $\lambda$  doğruluğu ile karşılaştırıldığında bağlı doğruluk, tahmin sonuçlarının belirli bir tolerans aralığına düşüp düşmediğini belirlemek yerine, daha nicel olarak değerlendirme yapar. Bağlı doğruluk için en üst değer 1 olup bu değer tahmin edilen KFÖ'nün gerçek KFÖ'ye eşit olduğu anlamına gelir. Şekil 3.25'te grafiksel olarak bağlı doğruluk gösterilmiştir [171].



Şekil 3.25: Bağlı doğruluk.

Bağıl doğruluk, belirli bir zaman için bilgi vermektedir. Algoritmanın zaman içindeki genel davranışını anlamak için  $t_\lambda$ 'dan önceki çoklu zaman örneklerinde durum değerlendirmesi istenebilir. Bu durum için kullanılan Kümülatif Bağıl Doğruluk (CRA), belirli zaman örneklerindeki bağıl doğrulukların normalleştirilmiş ağırlıklı toplamı olarak tanımlanmakta ve 3.34 eşitliği ile ifade edilmektedir.

$$CRA_\lambda^l = \frac{1}{|p_\lambda|} \sum_{i \in p_\lambda} w(r^l(i)) RA_\lambda^l \quad (3.34)$$

Burada,

$w(r^l(i))$ , tüm zaman endekslerinde KFÖ'nin bir fonksiyonu olarak bir ağırlık faktörüdür.

$p_\lambda$ , bir tahmin yapıldığında  $t_\lambda$ 'dan önceki tüm zaman indeksleri kümesidir.

$|p_\lambda|$  ise kümenin kardinalitesini göstermektedir.

## 4. BULGULAR


Bu bölümde tez çalışması kapsamında buraya kadar anlatılan veri işleme adımları ve yöntemler kullanılarak elde edilen sonuçlar paylaşılmıştır.

Bu çalışma kapsamında 1.test ve 2.test verileri kullanılarak diagnostik ve prognostik çalışması yapılmıştır. Literatürde bu veri seti ile üstel bozulma modeli kullanılarak herhangi bir prognostik çalışmasının yapılmadığı çeşitli akademik veri tabanlarında araştırma yapılarak teyit edilmiştir.


Diagnostik çalışması ile veri sahipleri tarafından deklare edilen arızaların oluştuğu çeşitli sinyal işleme teknikleri ile gösterilmiştir. Ardından yapılan prognostik modelleme ile oluşan arızaların ne zaman oluşacağı (kalan faydalı ömür) üstel bozulma modeli kullanılarak tahmin edilmiş ve tahmin performansları çeşitli metrikler ile ölçülmüştür.

### 4.1. DİAGNOSTİK ÇALIŞMASI BULGULARI

1.test ve 2.test için tüm rulmanları içerecek şekilde ölçümler (veri dosyaları) peş peşe eklendiğinde oluşan genlik-zaman grafikleri, oluşan arızalar ile birlikte Şekil 4.1 ve Şekil 4.2’de verilmiştir.



**Şekil 4.1:** 1.test boyunca rulmanlardaki titreşim seviyelerinin değişimi.




**Şekil 4.2:** 2.test boyunca rulmanlardaki titreşim seviyelerinin değişimi.

Şekil 4.1’de iç bilezik arızası oluşan 3.rulman ve Şekil 4.2’de dış bilezik arızası oluşan 1.rulman için test sonuna doğru titreşim seviyelerinin diğer rulmanlara göre önemli ölçüde artışı görülebilmektedir.

Daha önce Tablo 3.4’te verildiği gibi rulmana ait dış bilezik arıza frekansı (BPFO)236 Hz ve iç bilezik arıza frekansı (BPFI) ise 297 Hz olarak hesaplanmıştır. Diagnostik çalışması ile bu frekansların varlığı ve genliği araştırılacaktır.


Öncelikle Test2 & Rulman1 için verinin 1 sn’lik kısmı ile tamamı (984 ölçüm) Şekil 4.3’te verilmiştir.



**Şekil 4.3:** 2.test için 1 saniyelik ve tüm verinin değişimi.


Fourier dönüşümü sinyal içindeki frekans bilgisinin elde edilmesi amacıyla sıklıkla kullanılmaktadır. Erken aşama rulman arızalarında frekans bileşeni nispeten küçük olduğu için spektrum grafiği üzerinden yakalanması daha zordur. Dolayısıyla “zarf tekniği” yardımı ile küçük ancak tekrar eden arıza frekansları kuvvetlendirilir ve analiz daha kolay hale getirilir.

1sn’lik veri zaman domeninde açılarak gösterildiğinde periyodik genliklerden yaklaşık olarak BPFO frekansının elde edildiği görülebilir. Bu sinyal üzerinden zarf (envelope) sinyali Şekil 4.4’te verilmiştir.




**Şekil 4.4:** Ham sinyalde BPFO frekansında genlik modülasyonu ve zarf sinyali.

Verinin tamamı için 1kHz'e kadar olan zarf spektrum grafiği çizdirildiğinde BPFO frekansı ve harmoniklerinde oluşan genlikler Şekil 4.5'te açıkça görülmektedir.




Şekil 4.5: Test-2 & Rulman-1 verisi için zarf spektrumu.

Ayrıca Şekil 4.6’da frekansa (Hz) karşılık dB cinsinden güç spektrumu grafiği ile de başlangıçtan sona doğru BPFO frekansında (236Hz) oluşan genliğin artışı ve belirgin hale gelişi gösterilmiştir. Tüm bu sonuçlar test sonunda rulmanda dış bilezik arızası oluştuğunu göstermektedir.



Şekil 4.6: 2.test veri setinde baştan sona doğru BPFO genliklerinin değişimi.


Benzer adımlar Test-1 & Rulman-3 verisi için uygulanmış ve öncelikle elde edilen güç spektrum grafiği Şekil 4.7’de gösterilmiştir. Güç spektrumunda ilgili hasar frekansının (ve harmoniklerinin) oluştuğu net olarak görülmemektedir.




**Şekil 7:** Test-1 & Rulman-3 verisi için güç spektrumu grafiği.

Zarf spektrumu ise iki farklı frekans bandı için (3000Hz - 1000Hz) Şekil 4.8’de gösterilmiş olup bu grafikte BPFI frekansı ve onun 2.harmoniği olan 594Hz’e çok yakın oluşan genlik modülasyonu (602Hz) görülebilmektedir. Bununla birlikte iç bilezik hasar frekansının mil dönme frekansı (33,3Hz) ile modülasyona uğrayarak yan bantların oluştuğu da görülmektedir. İç bilezik şaft ile beraber döndüğünden bu durum iç bilezik arızaları için beklenen bir durumdur.

a)



b)



Şekil 4.8: Test-1 & Rulman-3 verisi zarf spektrumu: a) < 3000 Hz, b) < 1000 Hz.

## 4.2. PROGNOSTİK MODELLEME BULGULARI

Üçüncü bölümde bahsedildiği gibi prognostik süreci öncelikle seçilmiş özniteliklerin hesaplanması ile başlamaktadır. 1 saniyelik her ölçüm sinyali için belirlenen öznitelikler daha önce verilen hesaplama yöntemleri ile hesaplanarak analizde kullanılmıştır.

### 4.2.1. Test-2 Rulman-1 Veri Seti Prognostik Modelleme

Test-2 veri seti 1.rulmana ait veriler üzerinden hesaplanan toplam 24 adet öznitelik için ilk 15 adet öznitelik değeri örnek olarak Tablo 4.1’de verilmiştir.

**Tablo 4.1:** Test2-Rulman1 verisi için hesaplanan öznitelikler.

|    | 1       | 2          | 3          | 4          | 5          | 6         | 7           | 8           | 9             | 10           | 11                  | 12                  |
|----|---------|------------|------------|------------|------------|-----------|-------------|-------------|---------------|--------------|---------------------|---------------------|
|    | Mean    | Std        | Skewness   | Kurtosis   | Peak2Peak  | RMS       | CrestFactor | ShapeFactor | ImpulseFactor | MarginFactor | Energy              | SKMean              |
| 1  | -0.0291 | 0.1134     | 2.9551e-04 | 2.4998     | 0.6444     | 0.1171    | 2.5504      | 1.2236      | 3.1205        | 32.6172      | 35.1750             | 0.2003              |
| 2  | -0.0074 | 0.1137     | 0.0832     | 2.7549     | 0.7327     | 0.1139    | 3.4704      | 1.2355      | 4.2875        | 46.4958      | 33.3156             | 0.2835              |
| 3  | -0.0068 | 0.1161     | -0.0245    | 2.5159     | 0.7091     | 0.1163    | 3.0268      | 1.2177      | 3.6858        | 38.6078      | 34.6926             | 0.1990              |
| 4  | -0.0069 | 0.1178     | 0.1160     | 2.5698     | 0.7329     | 0.1180    | 3.0096      | 1.2164      | 3.6610        | 37.7352      | 35.7530             | 0.6458              |
| 5  | -0.0067 | 0.1184     | 0.0716     | 2.6786     | 0.8621     | 0.1185    | 4.0240      | 1.2259      | 4.9330        | 51.0143      | 36.0713             | 0.3716              |
| 6  | -0.0049 | 0.1173     | 0.0405     | 2.6346     | 0.8133     | 0.1173    | 3.9743      | 1.2215      | 4.8544        | 50.5364      | 35.3385             | 0.3157              |
| 7  | -0.0047 | 0.1202     | 0.0757     | 2.5362     | 0.7858     | 0.1203    | 3.5618      | 1.2173      | 4.3359        | 43.8722      | 37.1562             | 0.2808              |
| 8  | -0.0060 | 0.1182     | 0.0428     | 2.5781     | 0.7177     | 0.1184    | 2.8246      | 1.2160      | 3.4347        | 35.2800      | 35.9744             | 0.2831              |
| 9  | -0.0059 | 0.1216     | 0.0441     | 2.4921     | 0.7074     | 0.1217    | 2.8166      | 1.2121      | 3.4140        | 34.0086      | 38.0046             | 0.7775              |
| 10 | -0.0060 | 0.1187     | -0.0066    | 2.5281     | 0.7226     | 0.1188    | 3.3831      | 1.2113      | 4.0979        | 41.7772      | 36.2362             | 0.4025              |
| 11 | -0.0046 | 0.1209     | -0.0371    | 2.4692     | 0.6998     | 0.1209    | 2.9300      | 1.2102      | 3.5459        | 35.4873      | 37.5341             | 0.2860              |
| 12 | -0.0041 | 0.1200     | 0.0623     | 2.5697     | 0.7840     | 0.1200    | 3.3311      | 1.2217      | 4.0697        | 41.4285      | 36.9753             | 0.5542              |
| 13 | -0.0074 | 0.1197     | 0.0081     | 2.5443     | 0.7845     | 0.1199    | 3.3599      | 1.2143      | 4.0800        | 41.3075      | 36.9300             | 0.2430              |
| 14 | -0.0025 | 0.1198     | 0.0501     | 2.6043     | 0.7104     | 0.1198    | 2.8965      | 1.2179      | 3.5277        | 35.8643      | 36.8388             | 0.3935              |
| 15 | -0.0069 | 0.1216     | 0.0516     | 2.4345     | 0.6479     | 0.1218    | 2.6939      | 1.2116      | 3.2638        | 32.4732      | 38.0639             | 0.2829              |
|    | 13      | 14         | 15         | 16         | 17         | 18        | 19          | 20          | 21            | 22           | 23                  | 24                  |
|    | SKStd   | SKSkewness | SKKurtosis | MeanFreq   | MedFreq    | BandPower | SEMean      | SEStd       | SESkewness    | SEKurtosis   | Test2_Bearing1_BPFO | Test2_Bearing1_BPFI |
| 1  | 0.5030  | 1.0473     | 2.9703     | 3.0849e+03 | 3.1985e+03 | 0.0055    | 0.8762      | 0.0319      | -1.0525       | 4.9097       | 1.1547e-04          | 5.3418e-05          |
| 2  | 0.5979  | 0.5543     | 2.0885     | 3.2383e+03 | 3.4356e+03 | 0.0057    | 0.8853      | 0.0273      | -0.6089       | 3.4210       | 1.0074e-04          | 3.4521e-05          |
| 3  | 0.4917  | 0.4733     | 3.2810     | 3.1713e+03 | 3.3339e+03 | 0.0058    | 0.8802      | 0.0290      | -0.9623       | 5.8246       | 7.4167e-04          | 3.8855e-04          |
| 4  | 1.0311  | 1.2987     | 3.8054     | 3.1816e+03 | 3.3631e+03 | 0.0062    | 0.8765      | 0.0291      | -0.5236       | 3.3183       | 0.0010              | 6.3755e-04          |
| 5  | 0.6015  | 0.3077     | 2.4581     | 3.1923e+03 | 3.4534e+03 | 0.0062    | 0.8762      | 0.0288      | -0.5772       | 3.1977       | 3.7550e-04          | 1.4642e-04          |
| 6  | 0.6679  | 0.5136     | 2.5954     | 3.1895e+03 | 3.4211e+03 | 0.0061    | 0.8773      | 0.0266      | -0.5186       | 3.1789       | 2.8576e-04          | 1.1708e-04          |
| 7  | 0.5916  | 0.7757     | 3.0446     | 3.1274e+03 | 3.3258e+03 | 0.0062    | 0.8732      | 0.0286      | -0.5190       | 3.1893       | 3.7794e-04          | 1.7685e-04          |
| 8  | 0.4842  | 0.1713     | 2.8044     | 3.1761e+03 | 3.4354e+03 | 0.0060    | 0.8718      | 0.0296      | -0.5833       | 3.4570       | 1.1335e-04          | 4.9916e-05          |
| 9  | 1.3490  | 1.3846     | 4.1666     | 3.1234e+03 | 3.3286e+03 | 0.0062    | 0.8735      | 0.0280      | -0.6196       | 3.7109       | 7.8022e-05          | 2.1027e-05          |
| 10 | 0.6595  | 0.8635     | 3.6801     | 3.0710e+03 | 3.2902e+03 | 0.0057    | 0.8716      | 0.0293      | -0.5127       | 3.1993       | 0.0043              | 0.0010              |
| 11 | 0.5000  | 0.1495     | 2.7878     | 3.1349e+03 | 3.4297e+03 | 0.0063    | 0.8675      | 0.0297      | -0.6493       | 3.6211       | 3.1838e-04          | 2.1479e-04          |
| 12 | 1.0095  | 0.9286     | 2.4239     | 3.1208e+03 | 3.3906e+03 | 0.0060    | 0.8706      | 0.0300      | -0.4770       | 3.6963       | 2.4926e-04          | 1.0939e-04          |
| 13 | 0.5022  | 0.7717     | 4.3501     | 3.1217e+03 | 3.3685e+03 | 0.0060    | 0.8697      | 0.0292      | -0.5912       | 4.1838       | 5.9745e-04          | 5.8911e-04          |
| 14 | 0.8937  | 1.9399     | 6.8130     | 3.1730e+03 | 3.4712e+03 | 0.0064    | 0.8682      | 0.0299      | -0.3887       | 2.8439       | 3.8644e-04          | 2.8044e-04          |
| 15 | 0.6481  | 0.3839     | 1.9283     | 3.1379e+03 | 3.4119e+03 | 0.0063    | 0.8707      | 0.0278      | -0.4390       | 3.3068       | 1.3731e-04          | 1.0321e-04          |


BPFO ve BPFI genliklerinin hesaplanması için Bölüm 3.3.1’de bahsedildiği gibi öncelikle kurtogram fonksiyonu ile merkez frekans (fc) ve bant genişliği (BW) hesaplanmıştır. Şekil 4.9’da gösterildiği gibi hesaplanan değerler ve bant geçiren filtre aralığı aşağıdaki gibidir.

$$fc = 8960 \text{ Hz}, BW = 2560 \text{ Hz},$$


$$\text{Bant geçiren filtre aralığı } [fc-BW/2 \sim fc+BW/2]$$

$$\text{Bant geçiren filtre aralığı } [8960-2560/2 \sim 8960+2560/2] = [7680\text{Hz} \sim 10230\text{Hz}]$$

Hesaplanan bant geçiren filtre aralığı kullanılarak zarf analizinin sonraki adımları tamamlanmış ve zarf spektrumu hesaplanmıştır. Şekil 4.10'da gösterildiği gibi BPFO ve BPFI frekanslarına karşılık gelen genlik değerleri öznitelik değeri olarak alınmıştır.




Şekil 4.9: BPFO ve BPFI genlik hesaplamasında kullanılan kurtogram fonksiyonu.




Şekil 4.10: Hasar frekans genliklerinin hesaplanması.

Bu hesaplamalar her bir ölçüm sinyali için (1 saniyelik ölçüm) tek tek yapıldıktan sonra tüm veri için BPFO genlik grafiği Şekil 4.11'de, BPFI genlik grafiği ise Şekil 4.12'de gösterilmiştir.

İncelenen veri setinde (Rulman-1) her iki hasar frekansına ait genliklerin bir noktadan sonra artmaya başladığı ancak rulmanda dış bilezik arızası olduğu için BPFO genliklerindeki artışın BPFI genliklerine göre çok daha fazla olduğu kolayca görülebilmektedir. Dolayısıyla bu gözlem de dış bilezik arızasını teyit etmektedir.




Şekil 4.11: Test-2 & Rulman-1 BPFO genlik değişimi.




Şekil 4.12: Test-2 & Rulman-1 BPFI genlik değişimi.

Ayrıca db5 ana dalgacığı kullanılarak ve 3 seviye ayrıştırma şeklinde uygulanan ayrık dalgacık dönüşümü sonrası dönüştürülmüş sinyal üzerinden elde edilen spektral basırlıklın zaman ve frekansa göre değışimi Şekil 4.13'te gösterilmiştir. Testin sonuna yani arızanın oluşmasına doğru spektral basırlıklın artan bir trend göstermesi bu özneliğin potansiyel bir sağıık göstergesi olabileceğini göstermektedir.




Şekil 4.13: Test-2 & Rulman-1 verisi için spektral basırlıklık değışimi.

Elde edilen öznelilik tablosunda her bir öznelilik için hareketli ortalama yöntemi kullanılarak ilk seviye gürültü azaltma işlemi uygulanmıştır. Örnek olarak Şekil 4.14'te RMS özneliliğı için filtreleme öncesi ve sonrası görünümü verilmiştir.



**Şekil 4.14:** RMS için gürültü azaltma.

Mevcut arıza verisi üzerinden modelleme yapıldığından tüm verinin %50'sinin elimizde olduğu varsayımı ile her öznitelik için verilerin yarısı kullanılarak monotonluk hesabı yapılmıştır. Monotonluk seviyesi hangi özniteliklerin KFÖ tahmini için daha değerli olduğuna karar vermek için kullanılan kriterdir. Buna göre elde edilen monotonluk seviyeleri Şekil 4.15'te verilmiştir. Monotonluk seviyesi en yüksek olan ilk beş öznitelik (*MedFreq*, *Energy*, *RMS*, *SEStd*, *Std*) bundan sonraki aşama olan öznitelik birleştirme aşaması için seçilmiştir. Diğer öznitelikler artık hesaba katılmayacaktır. Seçilen özniteliklere ait ilk 15 değer örnek olarak Tablo 4.2'de verilmiştir.




Şekil 4.15: Test-2 & Rulman-1 için öznitelik monotonluk seviyeleri.

Tablo 4.2: Test-2 & Rulman-1 için seçilen öznitelikler ve ilk 15 veri.

|    | 1<br>MedFreq | 2<br>Energy | 3<br>RMS | 4<br>SEStd | 5<br>Std |
|----|--------------|-------------|----------|------------|----------|
| 1  | 3.1985e+03   | 35.1750     | 0.1171   | 0.0319     | 0.1134   |
| 2  | 3.3170e+03   | 34.2453     | 0.1155   | 0.0296     | 0.1136   |
| 3  | 3.3227e+03   | 34.3944     | 0.1157   | 0.0294     | 0.1144   |
| 4  | 3.3328e+03   | 34.7341     | 0.1163   | 0.0293     | 0.1153   |
| 5  | 3.3569e+03   | 35.0015     | 0.1168   | 0.0292     | 0.1159   |
| 6  | 3.3676e+03   | 35.0577     | 0.1169   | 0.0288     | 0.1161   |
| 7  | 3.3616e+03   | 35.3575     | 0.1173   | 0.0288     | 0.1167   |
| 8  | 3.3708e+03   | 35.4346     | 0.1175   | 0.0289     | 0.1169   |
| 9  | 3.3661e+03   | 35.7201     | 0.1179   | 0.0288     | 0.1174   |
| 10 | 3.3585e+03   | 35.7717     | 0.1180   | 0.0288     | 0.1175   |
| 11 | 3.3650e+03   | 35.9320     | 0.1183   | 0.0289     | 0.1178   |
| 12 | 3.3825e+03   | 36.0956     | 0.1186   | 0.0287     | 0.1184   |
| 13 | 3.3764e+03   | 36.4242     | 0.1191   | 0.0289     | 0.1190   |
| 14 | 3.3889e+03   | 36.6193     | 0.1194   | 0.0290     | 0.1193   |
| 15 | 3.3933e+03   | 36.8294     | 0.1198   | 0.0289     | 0.1197   |

Şekil 4.16’da seçilen 5 özniteliğin TBA yöntemi ile birleştirilerek tek bir sağlık göstergesi elde edilmesi gösterilmiştir.




**Şekil 4.16:** Test-2 & Rulman-1 için TBA ile elde edilen sağlık göstergesi.

Daha önce de bahsedildiği gibi üstel bozulma modeline uyum açısından sağlık göstergesi değişiminin monotonik olması gerekmektedir. Bu nedenle verideki anlık değişimlerin etkisini yok etmek (uzun vadeli trendi yakalamak) için LOESS (locally estimated scatterplot smoothing) metodu kullanarak ve 0,7 yumuşatma faktörü uygulayarak veri düzleştirme sağlanmıştır.

Ardından, elimizde geçmiş veri setleri olmadığından ve test sonunda bozulma meydana geldiğinden bu gösterge verisinin son değeri arıza eşik değeri olarak seçilmiştir.


Daha önce belirtildiği gibi standart sapma değişiminden hareketle verideki ani değişim tespit edilerek tahmin başlama noktası bulunmuştur. İlgili yardımcı fonksiyon ile bu sağlık göstergesi için 774.ölçüm verideki değişim noktası olarak tespit edilmiştir. Bozulmanın başladığı nokta olarak kabul edilen bu noktadan sonra KFÖ tahmin süreci başlatılacaktır. Şekil 4.17’de LOESS işlemi sonrası göstergedeki düzleşme ile beraber tahmin başlama noktası birlikte gösterilmiştir.



**Şekil 4.17:** Test-2 & Rulman-1 için LOESS işlemi ve TBN.


Nihai sağlık göstergesi ve tahmin başlama noktası belirlendikten sonra bu bilgiler üstel bozulma modelinin girişi (başlangıcı) olarak kullanılmıştır. Üstel bozulma modelinin parametreleri için varsayılan değerler seçilmiştir. Eşik değeri ise daha önce belirtildiği gibi sağlık göstergesinin son değeri olan “310.25” olarak alınmıştır.

Bölüm 3.3.5’te verilen varsayılan parametreler ile başlatılan üstel bozulma modeli her ölçüm için güncel bir KFÖ tahmini yapmaktadır. Sonuç olarak gerçek ve tahmini KFÖ eğrileri aşağıdaki gibi elde edilmektedir. Şekil 4.18’de gösterildiği gibi elde edilen modelin başlangıçta bir miktar sapma olsa da belli bir noktadan sonra gerçek KFÖ değerini yakın takip ettiği görülebilmektedir. Nihai KFÖ tahmini 1,1379 olarak hesaplanmıştır. Son gerçek KFÖ değeri ise 1 olduğundan model gerçek değerden sadece 0,1379 ölçüm daha geç (yaklaşık 1,38 dk) olacak şekilde tahmin yapmıştır.



**Şekil 4.18:** Test2 & Rulman1 için gerçek ve tahmini KFÖ değişimi.

Ayrıca Şekil 4.19’da  $\alpha$ - $\lambda$  grafiği çizdirilerek zamana bağlı olarak, KFÖ hesabı başladıktan sonra hangi zamanlarda KFÖ tahmininin güven aralığı içinde kaldığı görülebilmektedir. Bölüm 3.3.6.1’de belirtildiği üzere tez çalışması için  $\alpha=\pm\%30$  olarak alınmıştır.




Şekil 4.19: Test2 & Rulman1 için  $\alpha$ - $\lambda$  performans grafiği.

Tahmin performansı ayrıca KBD (CRA) metriği hesaplanarak değerlendirilmiştir. Bu metrik gerçek KFÖ değeri ve tahmin edilen KFÖ değeri arasındaki farkın her nokta için toplanması ile yapılan bir değerlendirmedir. 0 -1 arasında hesaplanan bu değer için literatürde herhangi bir sınır ya da kabul değeri bulunmamakta olup sonuç 1'e yaklaştıkça tahmin performansının arttığı anlaşılabılır. Bu veri seti ile ilgili yapılan tahmin için KBD değeri 0,74 olarak hesaplanmıştır.


#### 4.2.2. Test-1 Rulman-3 Veri Seti Prognostik Modelleme

Bu bölümde bir önceki bölümde yapılan tüm işlemler Test-1 veri seti 3.rulmana ait veriler için uygulanarak sonuçlar paylaşılmıştır. Bu veri seti için de aynı öznitelikler benzer şekilde hesaplanarak öznitelik tablosu oluşturulmuştur. Bu veri seti için potansiyel özniteliklerden BPFO ve BPFİ genlikleri ise Şekil 4.20 ve Şekil 4.21'de gösterildiği gibi elde edilmiştir.

İncelenen veri setinde her iki hasar frekansına ait genliklerin bir noktadan sonra artmaya başladığı ancak diğer veri setinin aksine rulmanda iç bilezik arızası olduğu için BPFİ genliklerindeki artışın BPFO genliklerine göre çok daha fazla olduğu kolayca görülebilmektedir. Dolayısıyla bu gözlem de iç bilezik arızası olabileceğini göstermektedir.




**Şekil 4.20:** Test-1 & Rulman-3 BPFI genlik değişimi.



**Şekil 4.21:** Test-1 & Rulman-3 BPFO genlik değişimi.


Benzer şekilde db5 ana dalgacığı kullanılarak ve 3 seviye ayrıştırma uygulanan ayırık dalgacık dönüşümü sonrası dönüştürülmüş sinyal üzerinden elde edilen spektral basıklığın zaman ve frekansa göre değişimi Şekil 4.22’de gösterilmiştir. Testin sonuna yani arızanın oluşmasına

doğru spektral basıklığın artan bir trend göstermesi yine bu özneliliğin potansiyel bir sağlık göstergesi olabileceğini göstermektedir.




**Şekil 4.22:** Test-1 & Rulman-3 verisi için spektral basıklık değışimi.

Elde edilen öznelilik tablosunda her bir öznelilik için hareketli ortalama yöntemi kullanılarak ilk seviye gürültü azaltma işlemi uygulanmıştır. Örnek olarak Şekil 4.23'te RMS özneliliği için filtreleme öncesi ve sonrası görünümü verilmiştir.



**Şekil 4.23:** Test-1 & Rulman-3 RMS özniteliği için gürültü azaltma.

Bu veri seti için daha başarılı sonuç alındığından tüm verinin %60'ının elimizde olduğu varsayımı ile her öznitelik için monotonluk hesabı yapılmıştır. Elde edilen monotonluk seviyeleri Şekil 4.24'te verilmiştir. Monotonluk seviyesi en yüksek olan ilk beş öznitelik (*SEStd*, *Energy*, *RMS*, *BandPower*, *Mean*) bundan sonraki aşama olan öznitelik birleştirme aşaması için seçilmiştir. Diğer öznitelikler artık hesaba katılmayacaktır. Seçilen özniteliklere ait ilk 15 değer ise örnek olarak Tablo 4.3'de verilmiştir.




Şekil 4.24: Test-1 & Rulman-3 için öznitelik monotonluk seviyeleri.

Tablo 4.3: Test-1 & Rulman-3 için seçilen öznitelikler ve ilk 15 veri

|    | 1<br>SEStd | 2<br>Energy | 3<br>RMS | 4<br>BandPower | 5<br>Mean |
|----|------------|-------------|----------|----------------|-----------|
| 1  | 0.0406     | 179.0672    | 0.2641   | 0.0166         | -0.2567   |
| 2  | 0.0394     | 180.7184    | 0.2653   | 0.0167         | -0.2578   |
| 3  | 0.0404     | 184.0875    | 0.2678   | 0.0169         | -0.2605   |
| 4  | 0.0404     | 185.1272    | 0.2685   | 0.0170         | -0.2612   |
| 5  | 0.0400     | 186.0877    | 0.2692   | 0.0170         | -0.2621   |
| 6  | 0.0403     | 185.9085    | 0.2691   | 0.0171         | -0.2621   |
| 7  | 0.0400     | 187.1763    | 0.2700   | 0.0172         | -0.2632   |
| 8  | 0.0409     | 188.0188    | 0.2706   | 0.0172         | -0.2641   |
| 9  | 0.0407     | 187.9564    | 0.2706   | 0.0172         | -0.2640   |
| 10 | 0.0409     | 187.7021    | 0.2704   | 0.0172         | -0.2641   |
| 11 | 0.0417     | 187.6997    | 0.2704   | 0.0172         | -0.2640   |
| 12 | 0.0420     | 187.7605    | 0.2704   | 0.0171         | -0.2642   |
| 13 | 0.0427     | 187.7893    | 0.2705   | 0.0171         | -0.2642   |
| 14 | 0.0427     | 188.2412    | 0.2708   | 0.0171         | -0.2645   |
| 15 | 0.0424     | 187.6540    | 0.2704   | 0.0171         | -0.2640   |


Şekil 4.25'te seçilen bu özniteliklerin TBA yöntemi ile birleştirilerek tek bir sağlık göstergesi elde edilmesi gösterilmiştir.



Şekil 4.25: Test-1 & Rulman-3 için TBA ile elde edilen sağlık göstergesi.

Üstel bozulma modeline uyum açısından sağlık göstergesi değişiminin monotonik olması gerektiğinden verideki uzun vadeli trendi yakalamak için daha önce uygulandığı gibi **LOESS** metodu kullanarak ve 0,9 yumuşatma faktörü uygulanarak veri düzleştirme sağlanmıştır.


Bu veri setinden elde edilen sağlık göstergesi için TBN 1665.ölçüm olarak hesaplanmıştır. Bozulmanın başladığı nokta olarak kabul edilen bu noktadan sonra KFÖ tahmin süreci başlatılacaktır. Şekil 4.26'da LOESS işlemi sonrası sağlık göstergesindeki yumuşatma ve tahmin başlama noktası birlikte gösterilmiştir. Diğer veri setinde olduğu gibi aynı varsayım ile verinin son değeri olan 1.56 arıza eşiği olarak kabul edilmiştir.




**Şekil 4.26:** Test-1 & Rulman-3 için LOESS işlemleri ve TBN.

Elde edilen nihai sağlık göstergesi üstel bozulma modelinin girişine uygulanmıştır. Bölüm 3.3.5'te verilen varsayılan parametreler ile başlatılan üstel bozulma modeli her ölçüm için güncel bir KFÖ tahmini yapmış ve sonuçta bu veri seti için Şekil 4.27'de verilen tahmin grafiği elde edilmiştir. Görüldüğü gibi elde edilen model diğer veri setine nazaran daha başarılı bir tahmin performansı göstermiş ve en baştan arızanın oluşma anına kadar gerçek KFÖ değerini yakın takip etmektedir. Bununla birlikte bozulma noktasına çok yakın olan bölgedeki sapmadan dolayı tahmin edilen son KFÖ değeri 20,45 olarak hesaplanmıştır. Son gerçek KFÖ değeri 1 olduğu için 19,45 yani 194 dakikalık bir fark ile tahmin yapılmıştır. Ancak toplam tahmin süreci göz önüne alındığında hesaplanan CRA değeri 0,85 olup endüstride pratik uygulama için yeterli olduğu görülmektedir.

Yine Şekil 4.28'de  $\alpha$ - $\lambda$  grafiği çizdirilerek zamana bağlı olarak, KFÖ hesabı başladıktan sonra hangi zamanlarda KFÖ tahmininin güven aralığı içinde kaldığı görülebilmektedir ( $\alpha$  değeri yine  $\pm\%30$  olarak alınmıştır). Güven aralığının son tahmin değerleri hariç tamamında toleranslar içinde kaldığı bu grafikten de görülebilmektedir.



Şekil 4.27: Test-1 & Rulman-3 için gerçek ve tahmini KFÖ değişimi.



Şekil 4.28: Test-1 & Rulman-3 için  $\alpha$ - $\lambda$  performans grafiği.

## 5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında endüstrinin en önemli ekipmanlarından olan asenkron motorlar ile birlikte kullanılan ve en sık karşılaşılan arızalardan olan rulman arızalarının önceden tespiti için bir kestirimci bakım uygulaması yapılmıştır. Son yıllarda yaşanan teknolojik gelişmeler sayesinde kestirimci bakım uygulamaları daha yaygın ve kolay uygulanabilir hale gelmiştir. Ayrıca daha maliyetli ve yıkıcı bir arıza oluşmadan önce sistemlere müdahale edilebilmesi kestirimci bakımın önemini artırmıştır.

Tez kapsamında yapılan ve kestirimci bakımın aşamalarından biri olan diagnostik çalışması ile oluşan arızaların ne olduğu belirlenebilmiştir. Ardından mevcut arıza verileri kullanılarak yapılan prognostik modelleme ile arızanın ne zaman oluşacağı tahmin edilmiş ve tahmin performansı sayısal olarak değerlendirilmiştir.

Prognostik daha yeni ve gelişmeye daha açık bir alan olarak çözülmeyi bekleyen bazı sorunlar da içermektedir [171]. Bunlardan ilki nedensellik olarak isimlendirilebilir. Prognostik, daha doğru tahminler yapabilmek için örneğin operasyonel koşullar ve yük profilleri hakkında bilgi gibi gelecekteki olaylardan girdi gerektiren nedensel bir problemdir. Ayrıca tahmin performansını doğru bir şekilde değerlendirmek için daha önceki ömür tahminleri ile karşılaştırmak gereklidir. Ekipmanın kullanım geçmişine ve kontrol edilemeyen gelecekteki işletme ve çevresel koşullara (örneğin hava koşulları) dayalı olarak bazı tahminler türetilebilir. Ancak bu durum genel sürece belirsizlik katar ve performansı mantıklı bir şekilde değerlendirmeyi zorlaştırır. İkinci sorun ise gerçek uygulamalardan elde edilen arıza verilerinin azlığıdır. Özellikle kritik sistemlerde arızaya izin verilmemesi tahminin gerçekten doğru olup olmadığını anlamayı engellemektedir. Ayrıca yapılan müdahale nedeniyle yeni ömür değişmiş olup tahmin sürecinin yeniden başlatılması gerekecektir.

Bu nedenlerle algoritma geliştirmek için laboratuvar ortamında hazırlanan düzenekler ile kontrollü bir şekilde arıza oluşturma ve veri toplama seçenekleri gündeme gelmiştir. Ancak bu durumda da çevrimdışı bir düzenek üzerinden elde edilen sonuçların gerçek çalışma ortamına genişletilmesi her zaman mümkün değildir. Bununla birlikte genellikle bu tarz bir çalışmada veri toplamak için düzenekte sık sık montaj ve demontaj işlemlerine ihtiyaç duyulur ve bu işlemler kısmi veri kaybına sebep olabileceği gibi sistem performansında farklılıklar yaratır ve arızalanma noktası, deneyin başında olabileceğinden farklı olarak değişir. Ayrıca kontrollü

deneyler, özellikle tüm bileşenler ve hata modları için istatistiksel olarak anlamlı sayıda deney yapılmak isteniyorsa, çok pahalı ve zaman alıcı olabilir.

Bu sorunların çözümü için basit bir yöntem olmamakla birlikte, çevresel koşulların beklenen limitler arasında kalacağı, olası herhangi bir değişimin sisteme majör bir etkisinin olmayacağı ve kontrol edilebilen bir değişikliği algoritmanın girdisi olarak kullanmak gibi varsayımlar ile değerlendirme yapılabilir.

Bir diğer sorun ise prognostik modellemedeki belirsizliktir. İyi bir prognostik sistemi, yalnızca kalan faydalı ömür için doğru tahminler sağlamakla kalmaz, aynı zamanda bu tür tahminlerle ilişkili güven düzeyini de belirler. Bu tür bilgiler olmadan herhangi bir prognostik tahminin kullanımı sınırlıdır ve kritik görev uygulamalarına dahil edilemez [16]. Bir PSY sisteminde çeşitli kaynaklardan belirsizlikler ortaya çıkabilir. Bunlar özetle; modellemeye ait belirsizlikler, kullanılan sensör ve gürültü kaynaklı ölçüm belirsizliği, çalışma ortamı belirsizlikleri, gelecekteki yük profili belirsizlikleri, girdi verisi belirsizlikleri (sistemin başlangıç durumunun tahmini, malzeme özelliklerindeki değişkenlik, üretim değişkenliği), vb. olarak sayılabilir [174-176].

Bu kaynakların her birinden kaynaklanan belirsizliklerin düzeylerini ve özelliklerini değerlendirmek genellikle zordur. Ayrıca, prognostik sürecin farklı aşamalarında ortaya çıkan bu belirsizliklerin, büyük olasılıkla karmaşık bir doğrusal olmayan dinamiğe sahip olan sistem boyunca nasıl birleştiğini ve yayıldığını değerlendirmek daha da zordur. İstatistiksel özellikler, analitik çözümlere izin veren bilinen herhangi bir parametrik dağılımı izlemiyorsa, bu sorun daha da kötüleşir. Tüm bu zorluklar nedeniyle belirsizliğin temsili ve yönetimi, PSY (Prognostik ve Sağlık Yönetimi) alanında aktif bir araştırma alanı haline gelmiştir.

Tez kapsamında kullanılan veri seti herkesin kullanıma açık bir veri seti olmasına rağmen prognostik amaçlı olarak daha önce üstel bozulma modeli ile herhangi bir çalışma yapılmadığı akademik veri tabanlarında yapılan araştırma ile teyit edilmiştir. Ayrıca belirtilen model aynı veri seti ile kullanılmış olsaydı bile veri ön işleme, gürültü giderme, öznitelik seçimi, dalgacık dönüşümü, öznitelik birleştirme, boyut azaltma, veri yumuşatma, tahmin başlama noktasının ve arıza eşiğinin belirlenmesi gibi birçok veri işleme adımlarında kullanılan teknikler, yapılan seçimler ve kabul edilen varsayımlar üstel bozulma modelinden bağımsız bir şekilde değiştirilebilir ve nihai tahmin performansı değerlendirilebilir.

Seilen parametreler ve varsayımlar ile KBD (kümülatif bağıl doğruluk) değeri ilk veri seti için 0,74 ve ikinci veri seti içinse 0,85 olarak elde edilmiş olup bu tahmin performansının seilen uygulama açısından yeterli olduğu değerlendirilmiştir. Prognostik modelleme ile elde edilen tahmin başlama noktaları değerlendirildiğinde, 1.test için arıza oluşmasından 35 saat önce ve 2.test için de yine arıza oluşmasından yaklaşık 82 saat önce tahmin sürecinin başladığı görülmekte olup kazanılan bu süre zarfında ilgili personelin gerekli bakım faaliyetlerini planlamaları sağlanabilmiştir.

Veri işleme adımlarında farklı parametreler seilerek ve iteratif bir şekilde denemeler yapılarak tahmin performansı yükseltilmeye çalışılabilir. KBD değeri başarılı bir tahmin performansı için kabul edilen bir sınır değeri olmamakla birlikte, 1'e ne kadar yakın olursa modelin o kadar başarılı bir tahmin yaptığı anlaşılabilir. Yapılan farklı çalışmalarda 0.53 ile 0.96 arasında farklı KBD değerleri elde edildiği görülmüştür.

Elde edilen prognostik model, laboratuvar ortamında kurulan bir düzenek üzerinden toplanan veriler ile geliştirilmiştir ve bu düzeneğin sabit çalışma koşulları (sıcaklık, hız, yük, çevresel etkiler, vb.) altında çalıştığı varsayılmıştır. Dolayısıyla modellemede bu tarz etkiler dikkate alınmamıştır. Gerçek saha uygulamalarında ise bu parametreler takip edilmeli ve modelin girdisi olarak bunların da etkisi değerlendirilmelidir. Ayrıca ara bakım, küçük tamir ve yağlama gibi faaliyetlerin oluşturduğu olay verilerinin de sensör ölçüm verileri kadar önemli olduğu unutulmamalıdır.

Kestirimci bakım ve prognostik modelleme konusunda araştırmacılar tarafından gelecekte yapılacak çalışmalara yön göstermesi açısından bazı öneriler aşağıda listelenmiştir:

- Tez çalışmasında ayrık dalgacık dönüşümü için db5 dalgacığı kullanılarak 3 seviye ayrıştırma yapılmıştır. Literatürde kullanılabilecek farklı ana dalgacıklar (smylet, coiflet, v.b.) ve bunların alt tipleri bulunmaktadır. Rulman arızaları için önerilen tek bir ana dalgacık seimi olmadığından diğerlerinin de test edilerek performansları değerlendirilebilir. Ayrıca literatürde rulman titreşim sinyallerinin analizinde kullanılacak en iyi ana dalgacığın seimi için çeşitli çalışmalar yapılmış ve bazı kriterler önerilmiştir. Bunlardan öne çıkan iki tanesi minimum shannon entropi kriteri ve maksimum enerji/shannon enerji oranı gibi kriterlerdir [177,178].

- Zaman ve frekans alanında toplam 24 öznitelik seçilerek veri işleme adımları bu öznitelikler üzerinden uygulanmıştır. İlerleyen adımlarda öznitelik seçimi yapılacağı gerekçesiyle fazla sayıda öznitelik ile başlanmasında herhangi bir problem görülmemiştir. Literatürde öznitelik sayısı ile ilgili bir kural veya sınırlama bulunmamaktadır. Araştırmacılar daha az veya daha çok sayıda ve farklı öznitelikler seçerek modelleme yapabilirler.
- Öznitelikler için monotonluk seviyesi en yüksek olan ilk 5 öznitelik sürecin devamında kullanılarak diğerleri kapsam dışı bırakılmıştır. Bu seçim ile ilgili literatürde kesin bir standart veya kriter bulunmamakta olup araştırmacılar farklı sayıda veya farklı kriterlere göre öznitelik seçimi yoluna gidebilirler.
- Boyut azaltma tekniği olarak kullanılan PCA, veri yumuşatma tekniği olarak kullanılan LOESS ve tahmin başlama noktasını bulmak için kullanılan teknikler yerine farklı yöntem ve algoritmalar denenerek performans karşılaştırması yapılabilir.
- Tez için kullanılan veri setinde sınırlı sayıda arıza verisi olduğu için (toplam 3 adet) üstel bozulma modeli varsayılan parametreler ile kullanılmıştır. Ancak daha fazla arıza verisi olması durumunda bu verileri kullanarak modelin başlangıç parametrelerini tahmin eden fonksiyonlar yardımı ile yeni başlangıç parametreleri kullanılabilir. Teknik olarak bu yöntem eldeki 3 arıza verisi için de uygulanabilir.
- Bilindiği gibi çeşitli veri işleme adımlarından sonra elde edilen sağlık göstergesi doğal olarak artan azalan şekilde bir dalgalanma gösterebilmektedir. Ancak üstel bozulma modelinin girdisi olacak bu göstergenin monotonik artan veya azalan bir trendi olması gerektiğinden, bu dalgalanmalar veri yumuşatma yöntemi ile ortadan kaldırılmıştır. Araştırmacılar bu dalgalanmaları farklı şekilde ele alarak, örneğin göstergeyi bölgesel olarak parçalara ayırıp, oluşan kısmi göstergelerin birleşiminden yeni bir gösterge elde etmek gibi yöntemleri araştırabilirler.

Sonuç olarak, her kestirimci bakım metodolojisinin benzersiz olduğunu ve uygulamaya bağlı olduğunu bilmek önemlidir. Elde edilen model ve sonuçlar çevre, üretilen veriler, ekipman ve diğer bazı parametrelere bağlıdır. Bunlardan herhangi biri değişirse, çoğu durumda metodolojinin de değiştirilmesi gerekir [179].

Bir işletmede bir kestirimci bakım stratejisinden iyi sonuçlar elde etmek için, modelleme amaçlı veri toplama sürecinde düzeltici (plansız) bakım ve periyodik bakım stratejilerini halihazırda

uygulamış olması gerektiğini belirtmek de önemlidir. Bu verilere dayanarak, kestirimci bakım için bir strateji tasarlamak ve doğrulamak mümkün hale gelir.

İnternet üzerinde farklı kurum veya kuruluşlar tarafından herkesin kullanımına açık olarak paylaşılan bu tarz veri setleri, kestirimci bakım konusunda farklı diagnostik ve prognostik modellerin geliştirilmesi, bu konuda bilgi birikiminin paylaşılması ve artırılması konusunda yeni araştırmacıları desteklemektedir.



## KAYNAKLAR

- [1]. Özer, A., *Üretim ve Üretim Yönetimi*, [https://acikders.ankara.edu.tr/pluginfile.php/57511/mod\\_resource/content/0/ACIK\\_DERS\\_URETIM\\_YONETIMI\\_1\\_HAFTA.pdf](https://acikders.ankara.edu.tr/pluginfile.php/57511/mod_resource/content/0/ACIK_DERS_URETIM_YONETIMI_1_HAFTA.pdf), [Ziyaret tarihi: 22 Aralık 2022].
- [2]. Ünal, G., 2009, *Güvenilirlik Merkezli Bakım ve Bir Endüstriyel Uygulama*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [3]. Yaman, G. ve Karadayı, H.M., 2014, Titreşim analizi ile pompalarda arıza tesbiti ve kestirimci bakım için örnek bir çalışma, *Tesisat mühendisliği*, (140), pp. 36–51, [https://mmo.org.tr/sites/default/files/0fc7ce64e252ead\\_ek.pdf](https://mmo.org.tr/sites/default/files/0fc7ce64e252ead_ek.pdf), [Ziyaret tarihi: 8 Ekim 2022].
- [4]. Üçüncü, K., 2017, *Bakım yönetimi*, <https://avesis.ktu.edu.tr/resume/downloadfile/kucuncu?key=0f64dfc2-11a0-49ed-92cf-a69131312373>, Karadeniz Teknik Üniversitesi, Orman Fakültesi, Orman Endüstri Mühendisliği Bölümü, Trabzon.
- [5]. Calabrese, F., Regattieri, A., Botti, L. and Galizia, F.G., 2019, Prognostic health management of production systems. New proposed approach and experimental evidences, *Procedia manufacturing*, 39. 260-269. 10.1016/j.promfg.2020.01.333.
- [6]. Siddiqui, K., Sahay, K. and Giri, V., 2014, Health monitoring and fault diagnosis in induction motor-A review, *International journal of advanced research in electrical, electronics and instrumentation engineering*, 3. 6549-6565.
- [7]. *Rulman arızaları sebepleri, belirtileri ve önlenmesi*, Kaplan Rulman, <https://www.kaplanrulmanltd.com/blog/rulman-arizalari-sebepleri-belirtileri-ve-onlenmesi>, [Ziyaret tarihi: 1 Aralık 2022].
- [8]. *Rulman malzemeleri güvenilirlik ve kalite* - nskeurope.com.tr, [https://www.nskeurope.com.tr/content/dam/nskcmsr/downloads/literature\\_bearing/P\\_TI-0106\\_TR.pdf](https://www.nskeurope.com.tr/content/dam/nskcmsr/downloads/literature_bearing/P_TI-0106_TR.pdf), [Ziyaret tarihi: 1 Aralık 2022].

- [9]. Köksal, M., Uzun, A., 2016, *Bakım onarım & Bakım planlaması*, Bilecik Şeyh Edebali Üniversitesi, [http://web.bilecik.edu.tr/bulent-turan/files/2016/03/bakim\\_onarim.pdf](http://web.bilecik.edu.tr/bulent-turan/files/2016/03/bakim_onarim.pdf), [Ziyaret Tarihi: 8 Ekim 2022].
- [10]. Er, E., 2004, *Bakım yönetimi ve bilgisayarlı bakım yönetim sistemlerinin Türkiye’de uygulama düzeyi*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [11]. Jardine, A.K.S., Lin, D. and Banjevic, D., 2006, A review on machinery diagnostics and prognostics implementing condition-based maintenance, *Mechanical systems and signal processing*, 20(7), pp. 1483–1510, <https://doi.org/10.1016/j.ymssp.2005.09.012>.
- [12]. H. Austerlitz, 2003, *Data Acquisition Techniques using PCs*, Academic Press, San Diego, CA.
- [13]. Kirianaki, N.V., Yurish, S.Y., Shpak, N.O. and Deynega, V.P., 2002, *Data Acquisition and Signal Processing for Smart Sensors*, Wiley, Chichester, West Sussex, England.
- [14]. Davies, C. and Greenough, R.M., 2000, The use of information systems in fault diagnosis, in: *Proceedings of the 16th National Conference on Manufacturing Research*, University of East London, UK.
- [15]. Bektaş, O., 2018, Çok boyutlu turbofan motoru durum izleme verilerinde prognostik uygulamalarının değerlendirilmesi, *Ondokuz Mayıs Üniversitesi, Samsun, VII. Ulusal havacılık ve uzay konferansı*, <https://www.researchgate.net/publication/327679969>, [Ziyaret tarihi: 8 Ekim 2022].
- [16]. Uckun, S., Goebel, K. and Lucas, P.J., 2008, Standardizing research methods for prognostics, *Physical review letters*, 1 - 10. 10.1109/PHM.2008.4711437.
- [17]. Gürsoy, M.Ü., Çolak, U. C., Gökçe, M.H., Akkulak, C. ve Ötleş, S., 2019, Endüstri için kestirimci bakım, *International journal of 3D printing technologies and digital industry*, Cilt 3, Sayı 1, s. 56-66.
- [18]. Williams, Z., Padraig, S. and Lueth, K.L., 2017, *Predictive maintenance–Market report 2017-2022*, IoTAnalytics GmbH, <https://iot-analytics.com/wp/wp->

content/uploads/2017/03/ Predictive-Maintenance-Market-Report-2017-2022-Mar-2017-vSAMPLE.pdf, [Ziyaret tarihi: 8 Ekim 2022].

- [19]. Aljumaili, M., Wandt, K., Karim, R. and Tretten, P., 2015, E-Maintenance ontologies for data quality support, *Journal of quality in maintenance engineering*, 21. 10.1108/JQME-09-2014-0048.
- [20]. *Overcoming four common obstacles to predictive maintenance with Matlab and Simulink*, MathWorks, <https://www.mathworks.com/campaigns/offers/predictive-maintenance-challenges.html>, [Ziyaret tarihi: 8 Ekim 2022].
- [21]. Wakiru, J., Pintelon, L., Muchiri, P. and Chemweno, P., 2018, A review on lubricant condition monitoring information analysis for maintenance decision support, *Mechanical systems and signal processing*, 118. 108-132. 10.1016/j.ymssp.2018.08.039.
- [22]. Dündar, D. R. , Sarıçiçek, İ. , Çınar, E. ve Yazıcı, A., 2021, Kestirimci bakımda makine öğrenmesi: literatür araştırması, *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 29 (2) , 256-276 . DOI: 10.31796/ogummf.873963
- [23]. Aliustaoğlu, C., 2008, *Rulman Arızalarının Gerçek Zamanda Analizi Ve Arıza Kaynaklarının Tespit Edilmesi*, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü.
- [24]. Koca, Y.B. and Ünsal, A., 2017, Asenkron motorların elektriksel ve mekaniksel arızalarının değerlendirilmesi, *Süleyman Demirel Üniversitesi Teknik Bilimler Dergisi*, 7(2), pp. 37–46.
- [25]. Orhan, S., 2002, *Rulmanlarla yataklanmış dinamik sistemlerin titreşim analiziyle kestirimci bakımı*, Doktora Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü.
- [26]. Camci, F., Medjaher, K., Zerhouni, N. and Nectoux, P., 2013, Feature evaluation for effective bearing prognostics, *Quality and reliability engineering international*, 29. 10.1002/qre.1396.

- [27]. Ayaz, E., 2002, *Elektrik motorlarında dalgacık analizi yaklaşımı ile rulman arıza tanısı ve yapay zeka tabanlı bir durum izleme sistemi*, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- [28]. Boudinar, A.H., Benouzza N., Bendiabdellah A. and Khodja M., 2016, Induction motor bearing fault analysis using a root-music method, *IEEE transactions on industry applications*, 52(5), 3851–60.
- [29]. Delgado-Arredondo, P. A., Morinigo-Sotelo, D., Osornio-Rios, R. A., Avina-Cervantes, J. G., Rostro-Gonzalez, H. and Jesus Romero-Troncoso, R., 2017, Methodology for fault detection in induction motors via sound and vibration signals, *Mechanical systems and signal processing*, 83, 568-589.
- [30]. Devaney, M. J. and Eren L., 2004, Detecting motor bearing faults: monitoring an induction motor's current and detecting bearing failure, *IEEE instrumentation and measurement magazine*, 7(4), 30–36.
- [31]. Farajzadeh-Zanjani, M., Razavi-Far, R., Saif, M., Zarei, J. and Palade, V., 2015, Diagnosis of bearing defects in induction motors by fuzzy-neighborhood density-based clustering. In *2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA)*, 935-940
- [32]. Immovilli, F., Bianchini, C., Cocconcelli, M., Bellini, A. and Rubini, R., 2013, Bearing fault model for induction motor with externally induced vibration. *IEEE Transactions on Industrial Electronics*, 60(8), 3408-3418.
- [33]. Jin, X., Zhao, M., Chow, T. W. and Pecht, M., 2014, Motor bearing fault diagnosis using trace ratio linear discriminant analysis. *IEEE Transactions on Industrial Electronics*, 61(5), 2441-2451.
- [34]. Orhan, S., Arslan H. ve Aktürk. N., 2003, Titreşim analiziyle rulman arızalarının belirlenmesi, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 18(2), 39–48.
- [35]. Senanayaka, J., Kandukuri, S., Khang, H.V. and Robbersmyr, K., 2017, Early detection and classification of bearing faults using support vector machine algorithm, 250-255. 10.1109/WEMDCD.2017.7947755.

- [36]. Tandon, N. and Choudhury, A., A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings, *Tribology International*, vol. 32, Issue 8, pp. 469-480, August 1999.
- [37]. Howard, I., 1994, A review of rolling element bearing vibration: detection, diagnosis and prognosis, *Defense science and technology organization*, Australian government department of defense.
- [38]. Singh, J., Azamfar, M., Li, F. and Lee, J., 2020, A systematic review of machine learning algorithms for PHM of rolling element bearings: fundamentals, concepts, and applications, *Measurement science and technology*. 10.1088/1361-6501/ab8df9.
- [39]. Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L. and Siegel, D., 2014, Prognostics and health management design for rotary machinery systems - Reviews, methodology and applications, *Mechanical systems and signal processing*, 42. 314-334. 10.1016/j.ymssp.2013.06.004.
- [40]. McFadden, P.D. and Toozhy, M.M., 2000, Application of synchronous averaging to vibration monitoring of rolling element bearings, *Mechanical systems and signal processing* 14 (2000) 891–906.
- [41]. Mechefske, C.K. and Mathew, J., 1992, Fault detection and diagnosis in low-speed rolling element bearings Part I: the use of parametric spectra, *Mechanical Systems and Signal Processing* 6 (1992) 297–307.
- [42]. Randall, R.B., 2005, Applications of spectral kurtosis in machine diagnostics and prognostics, *Key Engineering Materials* 293–294 (2005) 21–32.
- [43]. Qiu, H., Lee, J., Lin, J. and Yu, G., 2006, Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics, *Journal of Sound and Vibration*, 289 (2006) 1066–1090.
- [44]. Lei, Y., He, Z., Zi, Y. and Hu Q., 2007, Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs, *Mechanical Systems and Signal Processing* 21 (2007) 2280–2294.

- [45]. Yang, D.M., Stronach, A.F., Macconnell, P. and Penman, J., 2002, Third-order spectral techniques for the diagnosis of motor bearing condition using artificial neural networks, *Mechanical Systems and Signal Processing*, 16 (2002) 391–411.
- [46]. Wang, G., Luo, Z., Qin, X., Leng, Y. and Wang, T., 2008, Fault identification and classification of rolling element bearing based on time-varying autoregressive spectrum, *Mechanical Systems and Signal Processing*, 22 (2008) 934–947.
- [47]. Yu, D., Cheng, J. and Yang, Y., 2005, Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings, *Mechanical Systems and Signal Processing*, 19 (2005) 259–270.
- [48]. Chen, P., Taniguchi, M., Toyota, T. and He, Z., 2005, Fault diagnosis method for machinery in unsteady operating condition by instantaneous power spectrum and genetic programming, *Mechanical Systems and Signal Processing*, 19 (2005) 175–194.
- [49]. Rai, V.K. and Mohanty, A.R., 2007, Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform, *Mechanical Systems and Signal Processing*, 21 (2007) 2607–2615.
- [50]. Huang, R., Xi, L., Li, X., Liu, C.R., Qiu, H. and Lee, J., 2007, Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods, *Mechanical Systems and Signal Processing*, 21 (2007) 193–207.
- [51]. Yam, R.C.M., Tse, P.W., Li, L. and Tu, P., 2001, Intelligent predictive decision support system for condition-based maintenance, *International journal of advanced manufacturing technology*, 17 (2001) 383–391.
- [52]. Wang, P. and Vachtsevanos, G., 2001, Fault prognostics using dynamic wavelet neural networks, *Artificial intelligence for engineering design, Analysis and manufacturing*, 15 (2001) 349–365.
- [53]. Ocak, H., Loparo, K.A. and Discenzo, F.M., 2007, Online tracking of bearing wear using wavelet packet decomposition and probabilistic modeling: a method for bearing prognostics, *Journal of Sound and Vibration*, 32 (2007) 951–961.

- [54]. Satish, B. and Sarma, N.D.R., 2005, A Fuzzy BP approach for diagnosis and prognosis of bearing faults in induction motors, in: *Proceedings of the IEEE Power Engineering Society General Meeting*, vol. 3 (2005) pp. 2291–2294.
- [55]. Yang, J., Zhang, Y. and Zhu, Y., 2007, Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension, *Mechanical Systems and Signal Processing*, 21 (2007) 2012–2024.
- [56]. Feng, F.Z., Zhu, D., Jiang, P.C. and Jiang, H., 2009, GA-SVR based bearing condition degradation prediction, *Key Engineering Materials*, 413–414 (2009) 431–437.
- [57]. Li, Z., He, Z., Zi, Y. and Jiang, H., 2008, Rotating machinery fault diagnosis using signal-adapted lifting scheme, *Mechanical Systems and Signal Processing*, 22(2008) 542–556.
- [58]. Ling, W.Y., Jia, M.P., Xu, F.Y., Hu, J.Z. and Zhong, B.L., 2003, Optimizing strategy on rough set neural network fault diagnosis system, *Proceedings of the Chinese Society of Electrical Engineering*, 5 (2003) 98–102.
- [59]. Galati, F.A., Forrester, B.D. and Dey, S., 2008, Application of the generalized likelihood ratio algorithm to the detection of a bearing fault in a helicopter transmission, *Australian Journal of Mechanical Engineering*, 5 (2008) 169–175.
- [60]. Wang, W., 2002, A model to predict the residual life of rolling element bearings given monitored condition information to date, *IMA Journal of Management Mathematics*, 13 (2002) 3–16.
- [61]. Li, Y., Kurfess, T.R. and Liang, S.Y., 2000, Stochastic prognostics for rolling element bearings, *Mechanical Systems and Signal Processing*, 14 (2000) 747–762.
- [62]. Zhang, X., Xu, C.K.R., Liang, S.Y., Xie, Q. and Haynes, L., 2005, An integrated approach to bearing fault diagnostics and prognostics, in: *Proceedings of the American Control Conference*, vol. 4 (2005) pp. 2750–2755.
- [63]. Caesarendra, W., Widodo, A. and Yang, B. S., 2010, Application of relevance vector machine and logistic regression for machine degradation assessment, *Mechanical Systems*

*and Signal Processing*, 24(4), 1161–1171. Doi: <https://doi.org/10.1016/j.ymssp.2009.10.011>

- [64]. Pandya, D. H., Upadhyay, S. H. and Harsha, S. P., 2014, Fault diagnosis of rolling element bearing by using multinomial logistic regression and wavelet packet transform. *Soft Computing*, 18 (2) 255–266, 2014.
- [65]. Ahmad, W., Khan, S. A., Islam, M. M. M. and Kim, J.-M., 2018, A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*, 64, 67-76. Doi: <https://doi.org/10.1016/j.res.2018.02.003>
- [66]. Mahamad, A. K., Saon, S. and Hiyama, T., 2010, Predicting remaining useful life of rotating machinery based artificial neural network, *Computers & Mathematics with Applications*, 60(4), 1078–1087. Doi: <https://doi.org/10.1016/j.camwa.2010.03.065>
- [67]. Ben Ali, J., Chebel-Morello, B., Saidi, L., Malinowski, S. and Fnaiech, F., 2015, Accurate bearing remaining useful life prediction based on weibull distribution and artificial neural network, *Mechanical Systems and Signal Processing*, 56-57, 150–172. Doi: <https://doi.org/10.1016/j.ymssp.2014.10.014>
- [68]. Prieto, M. D., Cirrincione, G., Espinosa, A. G., Ortega J. A. and Henao, H., 2013, Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks, *IEEE Transactions on Industrial Electronics*, 60(8), 3398–3407.
- [69]. Ben Ali, J., Fnaiech, N., Saidi, L., Chebel-Morello, B. and Fnaiech, F., 2015, Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals, *Applied Acoustics*, 89, 16–27. Doi: <https://doi.org/10.1016/j.apacoust.2014.08.016>
- [70]. Lei, Y., Jia, F., Lin, J., Xing, S. and Ding, S. X., 2016, An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data, *IEEE Transactions on Industrial Electronics*, 63(5), 3137–3147. Doi: <https://doi.org/10.1109/TIE.2016.2519325>

- [71]. Saimurugan, M., Ramachandran, K. I., Sugumaran, V. and Sakthivel, N. R., 2011, Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine, *Expert Systems with Applications*, 38(4), 3819–3826. Doi: <https://doi.org/10.1016/j.eswa.2010.09.042>
- [72]. Soualhi, A., Medjaher, K. and Zerhouni, N., 2015, Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression, *IEEE Transactions on Instrumentation and Measurement*, 64(1), 52–62. Doi: <https://doi.org/10.1109/TIM.2014.2330494>
- [73]. Zhang, X., Liang, Y., Zhou, J. and Zang, Y., 2015, A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM, *Measurement*, 69, 164–179. Doi: <https://doi.org/10.1016/j.measurement.2015.03.017>
- [74]. Liao, L., Jin, W. and Pavel, R., 2016, Enhanced restricted boltzmann machine with prognosability regularization for prognostics and health assessment, *IEEE Transactions on Industrial Electronics*, 63(11), 7076–7083. Doi: <https://doi.org/10.1109/tie.2016.2586442>
- [75]. Jia, F., Lei, Y., Lin, J., Zhou, X. and Lu, N., 2016, Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, *Mechanical Systems and Signal Processing*, 72–73, 303–315. Doi: <https://doi.org/10.1016/j.ymssp.2015.10.025>
- [76]. Zhang, R., Peng, Z., Wu, L., Yao, B. and Guan, Y., 2017, Fault Diagnosis from Raw Sensor Data Using Deep Neural Networks Considering Temporal Coherence, *Sensors*, 17(3), 549. Doi: <https://doi.org/10.3390/s17030549>
- [77]. Chen, Z. and Li, W., 2017, Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network, *IEEE Transactions on Instrumentation and Measurement*, 66(7), 1693–1702. Doi: <https://doi.org/10.1109/tim.2017.2669947>

- [78]. Shao, H., Jiang, H., Lin, Y. and Li, X., 2018, A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders, *Mechanical Systems and Signal Processing*, 102, 278–297. Doi: <https://doi.org/10.1016/j.ymssp.2017.09.026>
- [79]. Zhang, B., Zhang, S. and Li, W., 2019, Bearing performance degradation assessment using long short-term memory recurrent network, *Computers in Industry*, 106, 14–29. Doi: <https://doi.org/10.1016/j.compind.2018.12.016>
- [80]. Zhang, H., Zhang, Q., Shao, S., Niu, T. and Yang, X., 2020, Attention-based LSTM network for rotatory machine remaining useful life prediction, *IEEE Access*, 8, 132188–132199. Doi: <https://doi.org/10.1109/access.2020.3010066>
- [81]. Prognostics Center of Excellence Data Set Repository, 2022, NASA. Available at: <https://www.nasa.gov/content/prognostics-center-of-excellence-data-set-repository/>, [Ziyaret tarihi: 15 Ekim 2021].
- [82]. PCB Piezotronics, <https://www.pcb.com/nx/search-results?q=353b33>, [Ziyaret tarihi: 15 Ekim 2022].
- [83]. Tyagi, S. and Panigrahi, S.K., 2017, An improved envelope detection method using particle swarm optimization for rolling element bearing fault diagnosis, *Journal of Computational Design and Engineering*, 4, 305–317. 10.1016/j.jcde.2017.05.002.
- [84]. Slavič, J., Brkovic, A. and Boltezar, M., 2011, Typical bearing-fault rating using force measurements: Application to real data, *Journal of Vibration and Control*, 17, 2164–2174. 10.1177/1077546311399949.
- [85]. Bessam B., Menacer A., Boumehraz A. and Cherif H., 2016, Detection of broken rotor bar faults in induction motor at low load using neural network, *ISA Trans.*, 64, 241–246, 2016.
- [86]. Elbouchikhi E., Choqueuse V., Amirat Y., Bembouzid M.E.H. and Turri S., 2017, An efficient Hilbert-Huang transform based bearing faults detection in induction machines, *IEEE Trans. Energy Convers.*, 32 (2), 401–413, 2017.

- [87]. Ghanbari T., 2016, Autocorrelation function-based technique for stator turn-fault detection of induction motor, *IET Science, Measurement & Technology*, 10 (2), 100-110, 2016.
- [88]. Kabul, A. and Ünsal, A., 2021, Detection of broken rotor bars of induction motors based on the combination of Hilbert envelope analysis and Shannon entropy, *tm - Technisches Messen*, 88. 45-58. 10.1515/teme-2020-0066.
- [89]. Talhaoui, H., Menacer, A., Kessal, A. and Ameid, T., 2018, Experimental diagnosis of broken rotor bars fault in induction machine based on Hilbert and discrete wavelet transforms, *The international journal of advanced manufacturing technology*, 95. 10.1007/s00170-017-1309-7.
- [90]. Özel site, 2022, Veri dağılımının şekli, <https://veribilimcisi.com/2021/01/22/veri-dagiliminin-sekli/>, [Ziyaret tarihi: 15 Ekim 2022].
- [91]. Wang, Y., Xiang, J., Markert, R. and Liang, M., 2015, Spectral kurtosis for fault detection, diagnosis and prognostics of rotating machines: A review with applications, *Mechanical Systems and Signal Processing*, 66. 10.1016/j.ymssp.2015.04.039.
- [92]. Randall, R.B., 2006, The spectral kurtosis: Application to the vibratory surveillance and diagnostics of rotating machines, *Mechanical Systems and Signal Processing*, 20. 308-331. 10.1016/j.ymssp.2004.09.002.
- [93]. Antoni J., 2007, Fast computation of the Kurtogram for the detection of transient faults. *Mech Syst Signal Process*, 2007; 21:108–24.
- [94]. International Organization for Standardization. Wind turbines – Part 4: Standard for Design and Specification of Gearboxes, ISO/IEC 81400–4:2005, Geneva, Switzerland: ISO, February 2005; 2005.
- [95]. Obeid, Z., Picot, A., Poignant, S., Regnier, J., Darnis, O. and Maussion, P., 2012, Experimental comparison between diagnostic indicators for bearing fault detection in synchronous machine by spectral Kurtosis and energy analysis, In: *IECON2012– 38th annual conference of IEEE Industrial electronics (IECON2012)*, 2012.p. 3901–06

- [96]. Antoni, J., 2006, The spectral kurtosis: a useful tool for characterising non-stationary signals, *Mechanical systems and signal processing*, Vol. 20, Issue 2, 2006, pp. 282–307.
- [97]. Saidi, L., Ben A.J., Bechhoefer, E. and Benbouzid, M., 2017, Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR, *Applied acoustics*, 120. 1-8. 10.1016/j.apacoust.2017.01.005.
- [98]. Pan, Y.N., Chen, J. and Li, X.L., 2009, Spectral Entropy: A complementary index for rolling element bearing performance degradation assessment, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, Vol. 223, Issue 5, 2009, pp. 1223–1231.
- [99]. Sharma, V. and Parey, A., 2016, A review of gear fault diagnosis using various condition indicators, *Procedia Engineering*, Vol. 144, 2016, pp. 253–263].
- [100]. Shen, J., Hung, J. and Lee, L., 1998, Robust entropy-based endpoint detection for speech recognition in noisy environments, *ICSLP*. Vol. 98, November 1998.
- [101]. Vakkuri, A., Yli-Hankala, A., Talja, P., Mustola, S., Tolvanen-Laakso, H., Sampson, T. and Viertiö-Oja., H., 2004, Time-frequency balanced spectral entropy as a measure of anesthetic drug effect in central nervous system during sevoflurane, propofol, and thiopental anesthesia, *Acta Anaesthesiologica Scandinavica*, Vol. 48, Number 2, 2004, pp. 145–153.
- [102]. Mittal, M., Shah, R.R. and Roy, S., 2021, Cognitive computing for human-robot interaction: Principles and practices, London, Academic Press.
- [103]. Uçan, O, N., 2003, İşaret ve görüntü işlemede yeni yaklaşımlar, İ.Ü. Mühendislik Fakültesi Yayınları, No:4408, 213s. İstanbul.
- [104]. Arı, N., Özen, Ş. and Çolak, Ö.H., 2008, Dalgacık teorisi, *Palme Yayıncılık*, pp. 51-75, Ankara.
- [105]. Öner, V., Yeşilyurt, M. and Yılmaz, E.Ç., 2017, Wavelet analiz tekniği ve uygulama alanları, *Ordu Üniversitesi Bilim ve Teknoloji Dergisi*, 7. 42-56.

- [106]. Fidan H., 2006, Dalgacık dönüşümü tekniği ile motor arıza tespiti, *Yüksek Lisans Tezi*, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü.
- [107]. Siddiqui, K.M. and Giri, V.K., 2012, Broken rotor bar fault detection in induction motors using wavelet transform, *Int. Conf Proc, IEEE, Computing, Electronics and Electrical Technologies [ICCEET]*., pp. 1-6, Chennai, India, March, 2012.
- [108]. Mehala, N., 2010, Condition Monitoring and Fault Diagnosis of Induction Motor using Motor Current Signature Analysis, *Ph.D. Thesis*, Electrical Engineering Department, NIT Kurukshetra, Oct. 2010
- [109]. Ye, Z., Wu, B. and Sadeghian, A., 2003, Current signature analysis of induction motor mechanical faults by wavelet packet decomposition, *IEEE Trans. Industrial Electronics*, Vol.50, No. 6, Dec.2003.
- [110]. Douglas, H., Pillay, P. and Ziarani, A.K., 2004, A new algorithm for transient motor current signature analysis using wavelets, *IEEE Transactions on Industry Applications*, Vol. 40, No. 5, Sept/Oct.2004
- [111]. Pons-Llinares, J, Antonino-Daviu, J, Roger-Folch, J., Morinigo-Sotelo, D. and Duque-Perez, O., 2010, Eccentricity diagnosis in inverter fed induction motors via the analytic wavelet transform of transient currents, *XIX International Conference on Electrical Machines (ICEM)*, pp.1 -6, 2010.
- [112]. Arashloo, R.S. and Jalilian, A., 2010, Design, implementation and comparison of two wavelet based methods for the detection of broken rotor bars in three phase induction motors, *1st Power Electronic & Drive Systems & Technologies Conference, PEDSTC*, pp.345 –35,2010.
- [113]. Turkmenoglu, M. A, 2010, Wavelet-based switching faults detection, *IET Science, Measurement and Technology*, Vol. 4, No. 6, pp.303–31,2010.
- [114]. Bayram, S., Kaplan, K., Kuncan, M. and Ertunc, H.M., 2014, The effect of bearings faults to coefficients obtained by using wavelet transform, *22nd Signal Processing and Communications Applications Conference, SIU 2014 – Proceedings*, 991-994. 10.1109/SIU.2014.6830398.

- [115]. Liao, L. and Lee, J., 2009, A novel method for machine performance degradation assessment based on fixed cycle features test, *J. Sound Vib.*, 326894–908.
- [116]. Zhang K., Li Y., Scarf P. and Ball A., 2011, Feature selection for high-dimensional machinery fault diagnosis data using multiple models and radial basis function networks, *Neurocomputing*, 742941–52.
- [117]. Robnik-Šikonja, M. and Kononenko, I., 2003, Theoretical and empirical analysis of ReliefF and RReliefF Mach, *Learn*, 5323–69.
- [118]. Samanta B, Al-Balushi K R. and Al-Araimi, S.A., 2003, Artificial neural networks and support vector machines with genetic algorithm for bearing fault detection, *Eng. Appl. Artif. Intell*, 16657–65.
- [119]. Lei, Y., Li, N., Guo, L., Li, N., Yan, T. and Lin, J., 2018, Machinery health prognostics: A systematic review from data acquisition to RUL prediction, *Mechanical systems and signal processing*, 104. 799-836. 10.1016/j.ymssp.2017.11.016.
- [120]. Niknam, S., Kobza, J. and Hines, J., 2017, Techniques of trend analysis in degradation-based prognostics, *The international journal of advanced manufacturing technology*, 88. 10.1007/s00170-016-8909-5.
- [121]. Widodo, A. and Yang, B.S., 2011, Application of relevance vector machine and survival probability to machine degradation assessment, *Expert Syst. Appl*, 38(2011) 2592–2599.
- [122]. Benkedjouh, T., Medjaher, K., Zerhouni, N. and Rechak, S., 2015, Health assessment and life prediction of cutting tools based on support vector regression, *J. Intell.Manuf.*, 26 (2015) 213–223.
- [123]. Wang, T., 2012, Bearing life prediction based on vibration signals: A case study and lessons learned, in: *IEEE International Conference on Prognostics and Health Management*, IEEE, Denver, CO, 2012, pp. 1–7.
- [124]. Mosallam, A., Medjaher, K. and Zerhouni, N., 2014, Time series trending for condition assessment and prognostics, *J. Manuf. Technol. Manage*, 25 (2014) 550–567.

- [125]. Zhao, M., Tang, B. and Tan, Q, 2016, Bearing remaining useful life estimation based on time–frequency representation and supervised dimensionality reduction, *Measurement*, 86 (2016) 41–55.
- [126]. Dong, S. and Luo, T., 2013, Bearing degradation process prediction based on the PCA and optimized LS-SVM model, *Measurement*, 46 (2013) 3143–3152.
- [127]. Tse, P.W. and Wang, D., 2015, Enhancing the abilities in assessing slurry pumps performance degradation and estimating their remaining useful lives by using captured vibration signals, *J. Vib. Control*, (2015) 1–13.
- [128]. Hair, J.F. et al., 2014, *Multivariate Data Analysis*, Upper Saddle River, NJ: Prentice Hall.
- [129]. Dar, A.N., 2021, Principal component analysis (PCA), *Global Scientific Journals*, 9(7).
- [130]. M, S., 2022, *Learn about principal component analysis in details*, *Analytics Vidhya*, <https://www.analyticsvidhya.com/blog/2022/03/learn-about-principal-component-analysis-in-details>, [Ziyaret tarihi: 15 Ekim 2022].
- [131]. Bektas, O., 2018, An Adaptive Data Filtering Model for Remaining Useful Life Estimation, *PhD Thesis*, University of Warwick.
- [132]. Duong, B.P., Khan, S., Shon, D., Im, K., Park, J., Lim, D., Jang, B. and Kim, J., 2018, A reliable health indicator for fault prognosis of bearings, *Sensors*, 18. 10.3390/s18113740.
- [133]. Ben, A.J., Saidi, L., Chebel-Morello, B. and Fnaiech, F., 2015, A new enhanced feature extraction strategy for bearing remaining useful life estimation, *STA 2014 - 15th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering*, 365-370. 10.1109/STA.2014.7086715.
- [134]. Nandi, S., Toliyat, H.A. and Xiaodong L., 2005, Condition monitoring and fault diagnosis of electrical motors-A review, *IEEE Transaction on Energy Conversion*, 20, pp. 719-729, 2005.

- [135]. Randall, R.B. and Antoni, J., 2011, Rolling element bearing diagnostics- A review, *Mechanical systems and signal processing*, 25, 485-520, 2011.
- [136]. Ahmad, W., Khan, S.A. and Kim, J., 2018, A hybrid prognostics technique for rolling element bearings using adaptive predictive models, *IEEE Trans. Ind. Electron*, 2018,65, 1577–1584.
- [137]. Elforjani, M. and Shanbr, S., 2018, Prognosis of bearing acoustic emission signals using supervised machine learning, *IEEE Trans. Ind. Electron*, 2018,65, 5864–5871.
- [138]. Javed, K., Gouriveau, R., Zerhouni, N. and Nectoux, P., 2015, Enabling health monitoring approach based on vibration data for accurate prognostics, *IEEE Trans. Ind. Electron*, 2015,62, 647–656.
- [139]. Lei, Y., Li, N., Guo, L., Li, N., Yan, T. and Lin, J., 2018, Machinery health prognostics: A systematic review from data acquisition to RUL prediction, *Mech. Syst. Signal Process*, 2018,104, 799–834.
- [140]. Qiu, H., Lee, J., Lin, J. and Yu, G., 2006, Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics, *J. Sound Vib.*, 2006,289, 1066–1090.
- [141]. Jacoby W.G., 2000, Loess: A nonparametric, graphical tool for depicting relationships between variables, *Electoral Studies*, 19, 577-613.
- [142]. Cleveland W.S., Devlin S.J. and Grosse E., 1988, Regression by local fitting: Methods, properties, and computational algorithms, *Journal of Econometrics*, 37(1), 87–114.
- [143]. Kurt, T., 2018, Kırmataş agregaların dane boyutu dağılımı ve şekilsel özelliklerinin görüntü analizi kullanılarak belirlenmesi, *Yüksek lisans tezi*, Zonguldak Bülent Ecevit Üniversitesi Fen Bilimleri Enstitüsü.
- [144]. Zheng, J. and Hryciw, R.D., 2015, Traditional soil particle sphericity, roundness and surface roughness by computational geometry. *Géotechnique*, 65(6): 494–506.
- [145]. Lei, Y., 2015, An improved exponential model for predicting remaining useful life of rolling element bearings, *IEEE Transactions on Industrial Electronics*, 62. 7762-7773.

- [146]. Wang, Y., Peng, Y., Zi, Y., Jin, X. and Tsui, K.L., 2016, A two-stage data-driven-based prognostic approach for bearing degradation problem, *IEEE Trans. Ind. Informat.*, vol. 12, no. 3, pp. 924–932, Jun. 2016.
- [147]. Lim, C.K.R. and Mba, D., 2015, Switching kalman filter for failure prognostic, *Mech. Syst. Signal Process.*, vol. 52, pp. 426–435, 2015.
- [148]. Ginart, A., Barlas, I., Goldin, J. and Dorrity, J.L., 2006, Automated feature selection for embeddable prognostic and health monitoring (PHM) architectures, *in Proc. IEEE Autotestcon*, 2006, pp. 195–201.
- [149]. Yang, B.S., 2012, An intelligent condition-based maintenance platform for rotating machinery, *Expert Syst. Appl.*, vol. 39, no. 3, pp. 2977–2988, 2012.
- [150]. Thoppil, N., Vasu, V. and Rao, C., 2021, Health indicator construction and remaining useful life estimation for mechanical systems using vibration signal prognostics, *International Journal of System Assurance Engineering and Management*, 12. 1-10. 10.1007/s13198-021-01190-z.
- [151]. Gebraeel, N., Lawley, M., Li, R. and Ryan, J., 2005, Residual-life distribution from component degradation signals: A Bayesian approach, *Iie Transactions*, 37. 543-557. 10.1080/07408170590929018.
- [152]. Soualhi, A., Razik, H., Clerc, G. and Doan, D.D., 2014, Prognosis of bearing failures using hidden markov models and the adaptive neuro-fuzzy inference system, *IEEE Trans. Ind. Electron.*, vol. 61, no. 6, pp. 2864–2874, Jun. 2014.
- [153]. Singleton, R.K., Strangas, E.G. and Aviyente, S., 2015, Extended kalman filtering for remaining-useful-life estimation of bearings, *IEEE Trans. Ind. Electron.*, vol. 62, no. 3, pp. 1781–1790, Mar. 2015.
- [154]. Tobon-Mejia, D.A., Medjaher, K., Zerhouni, N. and Tripot, G., 2012, A data-driven failure prognostics method based on mixture of gaussians hidden markov models, *IEEE Trans. Rel.*, vol. 61, no. 2, pp. 491–503, Jun. 2012.

- [155]. Javed, K., Gouriveau, R. and Zerhouni, N., 2014, A new multivariate approach for prognostics based on extreme learning machine and fuzzy clustering, *IEEE Transactions on Systems Man and Cybernetics Part B (Cybernetics)*, 45. 10.1109/TCYB.2014.2378056.
- [156]. Çamcı, F., Eker, Ö.F., Başkan, S. and Konur, S., 2016, Comparison of sensors and methodologies for effective prognostics on railway turnout systems, *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 230, 1 (2016), 24–42.
- [157]. Croarkin, C. and Tobias, P., 2006, Nist/Sematech e-handbook of statistical methods, *NIST/SEMATECH* (2006).
- [158]. Ramasso, E., 2014, Investigating computational geometry for failure prognostics, *International journal of prognostics and health management* 5, 1 (2014), 005.
- [159]. Saxena, A., Goebel, K., Don, S. and Eklund, N., 2008, Damage propagation modeling for aircraft engine run-to-failure simulation, *In Prognostics and Health Management*, 2008. PHM 2008, International Conference on. IEEE, 1–9.
- [160]. Wang, T., Yu, J., Siegel, D. and Lee, J., 2008, A similarity-based prognostics approach for remaining useful life estimation of engineered systems, *In Prognostics and Health Management*, PHM 2008. International Conference on. IEEE, 1–6.
- [161]. Gugulothu, N., Tv, V., Malhotra, P., Vig, L., Agarwal, P. and Shroff, G., 2017, Predicting remaining useful life using time series embeddings based on recurrent neural networks, *International journal of prognostics and health management*, 9.
- [162]. Shao, Y. and Nezu, K., 2000, Prognosis of remaining bearing life using neural networks, *Proc. Inst. Mech. Eng., J. Syst. Control Eng.*, pt. 1, vol. 214, no. 3, pp. 217–230, 2000.
- [163]. Gebraeel, N., Lawley, M., Liu, R. and Parmeshwaran, V., 2004, Residual life predictions from vibration-based degradation signals: a neural network approach, *Industrial electronics, IEEE Transactions*, on. 51. 694 - 700. 10.1109/TIE.2004.824875.

- [164]. Liao, H.T., Zhao, W.B. and Guo, H.R., 2006, Predicting remaining useful life of an individual unit using proportional hazards model and logistic regression model, *in Proc. Annu. Rel. Maintain. Symp.*, Newport Beach, CA, USA, Jan. 23–26, 2006, pp. 127–132.
- [165]. Tian, Z.G. and Liao, H.T., 2011, Condition based maintenance optimization for multi-component systems using proportional hazards model, *Rel. Eng. Syst. Safety*, vol. 96, no. 5, pp. 581–589, May 2011.
- [166]. Liao, L.X., 2014, Discovering prognostic features using genetic programming in remaining useful life prediction, *IEEE Trans. Ind. Electron.*, vol. 61, no. 5, pp. 2464–2472, May 2014.
- [167]. Gebraeel, N.Z., 2006, Sensory-updated residual life distributions for components with exponential degradation patterns, *IEEE Trans. Autom. Sci. Eng.*, vol. 3, no. 4, pp. 382–393, Oct. 2006.
- [168]. Elwany, A.H. and Gebraeel, N.Z., 2008, Sensor-driven prognostic models for equipment replacement and spare parts inventory, *IIE Trans.*, vol. 40, no. 7, pp. 629–639, Apr. 2008.
- [169]. You, M.Y., Liu, F., Wang, W. and Meng, G., 2010, Statistically planned and individually improved predictive maintenance management for continuously monitored degrading systems, *IEEE Trans. Rel.*, vol. 59, no. 4, pp. 744–753, Dec. 2010.
- [170]. Si, X.S., Wang, W.B., Chen, M.Y., Chang, H.H. and Dong, H.Z., 2013, A degradation path-dependent approach for remaining useful life estimation with an exact and closed-form solution, *Eur. J. Oper. Res.*, vol. 226, no. 1, pp. 53–66, Apr. 2013.
- [171]. Saxena, A., Celaya, J., Saha, B., Saha, S. and Goebel, K., 2010, Metrics for offline evaluation of prognostic performance, *International journal of prognostics and health management*, 1. 2153-2648. 10.36001/ijphm.2010.v1i1.1336.
- [172]. Saxena, A., Celaya, J., Saha, B., Saha, S. and Goebel, K., 2009, Evaluating algorithm performance metrics tailored for prognostics, *IEEE Aerospace Conference Proceedings*, 1 - 13. 10.1109/AERO.2009.4839666.

- [173]. Yang, F., Habibullah, M., Zhang, T., Xu, Z., Pin, L. and Nadarajan, S., 2016, Health index-based prognostics for remaining useful life predictions in electrical machines, *IEEE Transactions on Industrial Electronics*, 63. 1-1. 10.1109/TIE.2016.2515054.
- [174]. Coppe, A., Haftka, R. T., Kim, N. and Yuan, F., 2009, Reducing uncertainty in damage growth properties by structural health monitoring, *Annual conference of the prognostics and health management society*, (PHM09) San Diego, CA.
- [175]. Hastings, D. and McManus, H., 2004, A framework for understanding uncertainty and its mitigation and exploitation in complex systems, *Engineering Systems Symposium MIT*, Cambridge MA.
- [176]. Orchard, M., Kacprzynski, G., Goebel, K., Saha, B. and Vachtsevanos, G., 2008, Advances in uncertainty representation and management for particle filtering applied to prognostics, *International conference on prognostics and health management (PHM08)*, Denver, CO.
- [177]. Kumar, H.S., Pai, P., Sriram, N.S. and Gs, V., 2014, Selection of mother wavelet for effective wavelet transform of bearing vibration signals, *Advanced materials research*. 1039. 169-176. 10.4028/www.scientific.net/AMR.1039.169.
- [178]. Parmar, U. and Pandya, D., 2020, Selection of mother wavelet for fault detection of cylindrical bearing, 10.13140/RG.2.2.11094.57928.
- [179]. Carvalho, T., Soares, F., Vita, R., Francisco, R., Basto, J. and Symone, S.A.G., 2019, A systematic literature review of machine learning methods applied to predictive maintenance, *Computers & Industrial Engineering*, 137. 106024. 10.1016/j.cie.2019.106024.
- [180]. Geelen, B., 2008, Low-power, Wavelet-based Applications in Dynamic Environments.
- [181]. Altobi, M., Bevan, G., Wallace, P., Harrison, D.K. and Ramachandran, K.P., 2016, A review on applications of wavelet transform and artificial intelligence systems in fault diagnosis of rotating machinery.

## ÖZGEÇMİŞ

| Kişisel Bilgiler |                                                                          |
|------------------|--------------------------------------------------------------------------|
| Adı Soyadı       | Engin MÖNGÜ                                                              |
| Doğum Yeri       |                                                                          |
| Doğum Tarihi     |                                                                          |
| Uyruğu           | <input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer: |
| E-Posta Adresi   |                                                                          |
| Web Adresi       |                                                                          |

| Eğitim Bilgileri |                                       |
|------------------|---------------------------------------|
| Lisans           |                                       |
| Üniversite       | İstanbul Teknik Üniversitesi          |
| Fakülte          | Elektrik Elektronik Fakültesi         |
| Bölümü           | Elektronik ve Haberleşme Mühendisliği |
| Mezuniyet Yılı   | 1998                                  |

| Yüksek Lisans |                                                     |
|---------------|-----------------------------------------------------|
| Üniversite    | İstanbul Teknik Üniversitesi                        |
| Enstitü Adı   | Fen Bilimleri Enstitüsü                             |
| Anabilim Dalı | Elektronik ve Haberleşme Mühendisliği Anabilim Dalı |
| Programı      | Biyomedikal Mühendisliği                            |

| Doktora       |                          |
|---------------|--------------------------|
| Üniversite    | İstanbul Üniversitesi    |
| Enstitü Adı   | Fen Bilimleri Enstitüsü  |
| Anabilim Dalı | Enformatik Anabilim Dalı |
| Programı      | Enformatik Programı      |

| Makale ve Bildiriler |  |
|----------------------|--|
|                      |  |