



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**YAPAY ZEKA TEKNİKLERİNİ KULLANARAK RULMANLARDA
ARIZA VE KALAN FAYDALI ÖMÜR TAHMİNİ**

Eyyüp AKCAN

**Şubat-2025
BATMAN**

**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**

DOKTORA TEZİ

**YAPAY ZEKA TEKNİKLERİNİ KULLANARAK RULMANLARDA
ARIZA VE KALAN FAYDALI ÖMÜR TAHMİNİ**

Eyyüp AKCAN

**Danışman
Doç. Dr. Yılmaz KAYA**

Diğer Jüri Yeleri

**Doç. Dr. Mehmet Recep MİNAZ
Doç. Dr. Melih KUNCAN**

**Doç. Dr. Mehmet Rıda TÜR
Dr. Öğr. Üyesi Davut SEVİM**

**Şubat-2025
BATMAN**

TEZ KABUL VE ONAYI

Eyyüp AKCAN tarafından hazırlanan “Yapay Zeka Tekniklerini Kullanarak Rulmanlarda Arıza ve Kalan Faydalı Ömür Tahmini” adlı tez çalışması 27/02/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Ana Bilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Mehmet Recep MİNAZ

.....

Danışman

Doç. Dr. Yılmaz KAYA

.....

Üye

Doç. Dr. Mehmet Rıda TÜR

.....

Üye

Doç. Dr. Melih KUNCAN

.....

Üye

Dr. Öğr. Üyesi Davut SEVİM

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Eyyüp AKCAN
27/02/2025

ÖZET

DOKTORA TEZİ

YAPAY ZEKA TEKNİKLERİNİ KULLANARAK RULMANLARDA ARIZA VE KALAN FAYDALI ÖMÜR TAHMİNİ

Eyyüp AKCAN

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Yılmaz KAYA

2025, 117 Sayfa

Bu tez, endüstriyel makinelerin kritik bileşenlerinden biri olan rulmanların arıza teşhisi ve ömrü tahmini konularında yenilikçi yaklaşımlar sunmaktadır. Rulmanların arızalanması, makine performansında ciddi kayıplara ve yüksek ekonomik maliyetlere yol açabileceği için, bu alandaki erken teşhis ve ömür tahmin çalışmaları büyük bir önem taşımaktadır. Çalışmada, rulman arızalarının teşhisi için lazer ışını kullanarak yapay hatalar oluşturulmuş ve bu hatalar farklı hız ve yük koşullarında detaylı titreşim analiziyle incelenmiştir. Entropi tabanlı 18 farklı yöntemle öznitelikler çıkarılmış ve söz konusu öznitelikler Ekstrem Öğrenme Makinesi (ELM) modeli ile sınıflandırılmıştır. Özellikle Fuzzy Entropi ve Slope Entropi yöntemleri, sırasıyla %98.48 ve %100 doğruluk oranlarıyla yüksek performans sergilemiştir. Önerilen yöntem, literatürdeki diğer modern yaklaşımlarla karşılaştırıldığında üstünlük göstermiştir. Çalışmanın bir diğer önemli kısmı, MM-1D-LBP yöntemi ile öznitelik çıkarımı ve 1D-CNN-LSTM tabanlı hibrit bir model kullanılarak rulman arızalarının tahmin edilmesidir. Bu yöntemle %99.31 ile %99.65 doğruluk oranları elde edilmiştir. Literatürde sıklıkla kullanılan GRU ve LSTM tabanlı modellerle kıyaslandığında, önerilen yaklaşım daha yüksek doğruluk sunmuş ve özellikle karmaşık arıza tiplerinin sınıflandırılmasında başarılı olmuştur. Rulman ömrü tahmini kapsamında, 1D-TP ve LSTM modellerinin birleştirildiği bir yöntem geliştirilmiş ve bu yöntem, Pronostia platformundaki veri setleri üzerinde test edilmiştir. Titreşim sinyallerine dayalı olarak yapılan analizlerde, Bearing3_3 senaryosunda RMSE=0.0470 ve Score=0.6360 gibi düşük hata ve yüksek performans değerleri elde edilmiştir. Önerilen model, literatürdeki diğer yöntemlere kıyasla daha düşük hata oranları ile öne çıkmaktadır. Örneğin, Bi-LSTM (RMSE=0.2300) ve Relief-SVM (RMSE=0.2500) gibi yöntemlere kıyasla, önerilen 1D-TP+LSTM modelinin RMSE değeri 0.2074 olarak kaydedilmiş ve daha iyi bir tahmin doğruluğu sağlanmıştır. Sonuç olarak, bu çalışma, entropi tabanlı ELM ve 1D-TP+LSTM gibi yenilikçi yöntemlerle hem arıza teşhisi hem de ömür tahmini alanlarında önemli katkılar sunmaktadır. Geliştirilen modeller, endüstriyel bakım süreçlerinde daha hızlı, güvenilir ve düşük maliyetli çözümler sağlamaktadır. Çalışma bulguları hem akademik literatüre hem de endüstriyel uygulamalara değerli bir referans oluşturmaktadır. Gelecekte, farklı veri setleri ve çalışma koşullarında modelin genelleme kapasitesinin artırılması ve entropi yöntemlerinin çeşitlendirilmesi, önerilen yaklaşımların etkinliğini daha da artırabilir.

Anahtar Kelimeler: 1D-CNN, 1D-LBP, ELM, Entropi Varyantları, LSTM, Rulman Arıza, RUL

ABSTRACT
DOCTORAL THESIS
BEARING FAILURE AND REMAINING USEFUL LIFE ESTIONS USING
ARTIFICIAL INTELLIGENCE TECHNIQUES

Eyyüp AKCAN

Batman University Graduate Education Institute

Department of Electrical and Electronics Engineering

Advisor: Assoc. Prof. Dr. Yılmaz KAYA

2025, 117 Pages

This study presents innovative approaches for fault diagnosis and life prediction of bearings, which are critical components of industrial machines. Bearing failures can lead to significant performance losses and high economic costs, emphasizing the importance of early diagnosis and life prediction in this field. In the study, artificial defects were created using laser beams, and these defects were analyzed in detail through vibration analysis under varying speed and load conditions. Features were extracted using 18 different entropy-based methods and classified using the Extreme Learning Machine (ELM) model. Notably, Fuzzy Entropy and Slope Entropy methods demonstrated high performance with accuracy rates of 98.48% and 100%, respectively. The proposed method outperformed other modern approaches in the literature. Another significant aspect of the study involves the use of the MM-1D-LBP method for feature extraction and a hybrid 1D-CNN-LSTM-based model for fault prediction. This method achieved accuracy rates of 99.31% to 99.65%. Compared to commonly used models in the literature, such as GRU and LSTM, the proposed approach provided higher accuracy, particularly in classifying complex fault types. For bearing life prediction, a method combining 1D-TP and LSTM models was developed and tested on datasets from the Pronostia platform. In analyses based on vibration signals, the Bearing3_3 scenario yielded low error and high performance metrics, with RMSE = 0.0470 and Score = 0.6360. The proposed model stands out with lower error rates compared to other methods in the literature. For instance, the Bi-LSTM model (RMSE = 0.2300) and the Relief-SVM model (RMSE = 0.2500) showed inferior accuracy compared to the proposed 1D-TP+LSTM model, which achieved an RMSE of 0.2074. In conclusion, this study offers significant contributions in fault diagnosis and life prediction through innovative methods such as entropy-based ELM and 1D-TP+LSTM. The developed models provide faster, more reliable, and cost-effective solutions in industrial maintenance processes. The findings of the study serve as a valuable reference for both academic literature and industrial applications. In the future, enhancing the generalization capacity of the model with different datasets and operating conditions, as well as diversifying entropy methods, could further improve the effectiveness of the proposed approaches.

Keywords: 1D-CNN, 1D-LBP, Bearing Failure, ELM, Entropy Variants, LSTM, RUL

ÖN SÖZ

Öncelikle, doktora öğrenim sürecimin her aşamasında beni yönlendiren, bilgi ve tecrübeleriyle akademik gelişimime paha biçilmez katkılar sağlayan, her zaman ilham verici bir rehber ve destekçi olan kıymetli danışman hocam Sayın Doç. Dr. Yılmaz KAYA'ya sonsuz teşekkürlerimi ve derin saygılarımı sunarım. Kendisi, bu süreç boyunca yalnızca akademik anlamda değil, kişisel anlamda da örnek bir liderlik sergileyerek beni her zaman motive etmiş ve ufkumu genişletmiştir.

Bu çalışmada kullanılan rulman verilerini paylaşarak araştırmamıza büyük katkı sağlayan Sayın Prof. Dr. Hüseyin Metin ERTUNÇ, Dr. Öğr. Üyesi Kaplan KAPLAN hocam ve Kocaeli Üniversitesi sensör laboratuvarı ekibine sonsuz teşekkürlerimi sunarım. Verdikleri destek ve sağladıkları değerli veriler, çalışmamızın bilimsel niteliğini artırmada önemli bir rol oynamıştır.

Tez izleme sürecinde değerli eleştirileri, yapıcı önerileri ve yönlendirmeleriyle çalışmama büyük katkılar sağlayan Sayın Doç. Dr. Mehmet Recep MİNAZ ve Sayın Doç. Dr. Mehmet Rida TÜR'e şükranlarımı sunarım. Özellikle, Sayın Doç. Dr. Mehmet Recep MİNAZ'ın samimi destekleri ve süreç boyunca gösterdiği değerli ilgisi benim için her zaman büyük bir motivasyon kaynağı olmuştur. Ayrıca, süreç boyunca desteğini ve katkılarını esirgemeyen Sayın Doç. Dr. Melih KUNCAN'a da teşekkür ederim.

Hayatımın her döneminde yanımda olan, duaları ve varlıklarıyla bana güç veren sevgili anne ve babama en derin şükranlarımı sunarım. Bu süreçte gösterdikleri destek, benim için her zaman bir dayanak noktası olmuştur.

Ayrıca, bu süreçte sevgisi, sabrı ve anlayışıyla her zaman yanımda olan sevgili eşime minnettarlığımı ifade etmek isterim. Hayatımın en değerli varlıkları olan sevgili çocuklarım Yusuf Talha, Muhammed Ali ve Ömer'e de sevgilerimi sunarım. Onların neşesi, sevgisi ve varlığı, bu zorlu süreçte bana güç ve huzur veren en büyük kaynağım olmuştur.

Bu tezi, benimle birlikte bu süreci paylaşan ve her anımı güzelleştiren sevdiklerime ithaf ediyorum...

Eyyüp AKCAN
BATMAN-2025

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	12
2.1. Rulman Arıza Tespiti ile İlgili Literatür Çalışmaları.....	12
2.2. Rulman Ömrü Tespiti ile İlgili Literatür Çalışmaları	23
3. MATERYAL VE YÖNTEM.....	35
3.1. Materyal	35
3.1.1. Rulman arıza tespiti için kullanılan veri setleri	35
3.1.2. Rulman ömrü tahmini için kullanılan veri seti	40
3.2. Metot	45
3.2.1. Aşırı makine öğrenmesi ile entropi varyantlarını kullanarak rulman arıza teşhisi	45
3.2.1.1. Özellik çıkarım yöntemleri	45
3.2.2. Aşırı öğrenme makinası	63
3.2.3. Rulman arızalarının tespiti için 1d-lbp ile hibrit derin öğrenme tabanlı yaklaşım	65
3.2.3.1. Min-max(mm) 1d-lbp	65
3.2.3.2. 1D-CNN.....	69
3.2.3.3. LSTM.....	70
3.2.3.4. Önerilen yaklaşım	71
3.2.4. Rulmanların kalan faydalı ömrünün tahmini için yaklaşım.....	73
3.2.4.1 Üçlü desenler yöntemi	73
3.2.4.2. Önerilen yaklaşım	76
3.2.5. Performans ölçütleri.....	77
3.2.5.1. Sınıflandırma performans ölçütleri	77
3.2.5.2. Rul tahmini için performans ölçütleri	78
4. BULGULAR VE TARTIŞMA.....	79
4.1. Aşırı Makine Öğrenmesi ile Entropi Varyantlarını Kullanarak Rulman Arıza Teşhisi.....	79
4.2. Rulman Arızalarının Tespiti İçin 1D-LBP ile Hibrit Derin Öğrenme Tabanlı Yaklaşım	85

4.3 LSTM ile 1D-TP Desenler Kullanılarak Rulmanların Kalan Faydalı Ömrünün Tahmini İçin Yeni Bir Yaklaşım	89
5. SONUÇLAR VE ÖNERİLER	98
5.1. Rulman Arızalarına Yönelik Sonuç ve Öneriler	98
5.1.1. Aşırı makine öğrenmesi ile entropi varyantlarını kullanarak rulman arıza teşhisi	98
5.1.2. Rulman arızalarının tespiti için 1d-lbp ile hibrit derin öğrenme tabanlı yaklaşım	101
5.2. Rulman Ömür Tahminine Yönelik Sonuç ve Öneriler	104
5.3. Gelecekte Yapılabilecek Çalışmalar	107
KAYNAKLAR	108



TABLolar LİSTESİ

Tablo 3. 1. Veri seti1 farklı hızlar için oluşturulan veri kümesi	36
Tablo 3. 2. Veri seti2 rulman arıza tipleri için oluşturulan veri seti	36
Tablo 3. 3. Veri seti3 OR için rulman hata boyutları veri seti.....	36
Tablo 3. 4. Veri seti1 rulman arıza tipleri için oluşturulan veri seti	38
Tablo 3. 5. Veri seti2 BS için rulman arıza boyutlarına ilişkin veri seti	39
Tablo 3. 6. Pronostia platformundan elde edilen veri setleri	41
Tablo 3. 7. Deneysel senaryolar.....	42
Tablo 4. 1. ELM modeli parametreler	80
Tablo 4. 2. Başarı Oranları.....	80
Tablo 4. 3. Performans Ölçütleri	80
Tablo 4. 4. Her entropiye ait başarı oranı	81
Tablo 4. 5. Nöron sayısına göre başarı oranları	82
Tablo 4. 6. Aktivasyon fonksiyonlarına göre başarı oranları	83
Tablo 4. 7. Farklı makine öğrenmesi yöntemlere ait başarı oranları	83
Tablo 4. 8. Comparative results with other methods on the bearing failure dataset.....	84
Tablo 4. 9. Farklı eğitim-test oranları için MM-1D-LBP+1D-CNN+LSTM ile edilen başarı oranları	85
Tablo 4. 10. MM-1D-LBP +1D-CNN+LSTM ile performans ölçütleri.....	86
Tablo 4. 11. LSTM, GRU, 1D-CNN ve önerilen metodun başarı değerleri.....	87
Tablo 4. 12. Rulman arıza teşhisinde diğer yöntemlerle karşılaştırmalı sonuçlar.	89
Tablo 4. 13. LSTM ağı hiper parametreler	90
Tablo 4. 14. Up features için elde edilen performans değerleri.....	91
Tablo 4. 15. Low Features için elde edilen performans değerleri	91
Tablo 4. 16. β parametresinin farklı değerlerine göre elde edilen başarı oranları	95
Tablo 4. 17. Rulman1_3 ve Rulman3_3 için tahmini ve hesaplanan RUL	96
Tablo 4. 18. Önerilen yönteme ait performans değerlerin literatürdeki çalışmalar ile karşılaştırılması.....	97
Tablo 5. 1. Rulman arızası veri seti üzerinde diğer yöntemlerle karşılaştırmalı sonuçlar	99
Tablo 5. 2. Rulman arıza teşhisinde diğer yöntemlerle karşılaştırmalı sonuçlar.	104
Tablo 5. 3. Önerilen yönteme ait performans değerlerin literatürdeki çalışmalar ile karşılaştırılması.....	105

ŞEKİLLER LİSTESİ

Şekil 1.1. Bir rulmanın elemanları (Ali, R. 2017)	1
Şekil 3. 1. Titreşim verisi toplama şeması	35
Şekil 3. 2. Farklı RPM’lerde elde edilen örnek işaretler. (A) 1500 RPM, (B) 1740 RPM, (C) 1800 RPM, (D) 1860 RPM, (E) 2100 RPM.	37
Şekil 3. 3. Farklı hata türlerine ait işaretler. (A) İç bilezik hatalı, (B) Dış bilezik hatalı, (C) bilezik hatalı, (D) Hatasız işaretler	37
Şekil 3. 4. Farklı boyutlardaki hatalara ait örnek işaretler. (A) 0.15 mm hatalı, (B) 0.9 mm hatalı, (C) 0.5 mm hatalı, (D) hatasız işaretler	38
Şekil 3. 5. Farklı arıza tiplerinin sinyalleri. (A) Arızasız, (B) İç halka arızası, (C) Dış halka arızası (D) Küresel arıza.....	39
Şekil 3. 6. Farklı arıza boyutlarının örnek sinyalleri (A) 0,15 mm Arıza, (B) 0,9 mm Arıza, (C) 0,5 mm Arıza (D) Arızasız sinyaller	40
Şekil 3. 7. The pronostia platform (Nectoux ve ark., 2012)	41
Şekil 3. 8. Bearing1_1 için (A) örnek titreşim sinyalleri, (B) titreşim sinyallerine ait RMS değerleri.....	43
Şekil 3. 9. Titreşim sinyallerindeki RMS değerleri ve sinyallerdeki dalgalanmalar	43
Şekil 3. 10. Rulman ömür gösterimleri.....	44
Şekil 3. 11. İleri beslemeli yapay sinir ağı.....	64
Şekil 3. 12. MM-1D-LBP yönteminin anlatımı için örnek titreşim sinyal parçası.....	66
Şekil 3. 13. Olası 1D-LBP Operatörler	67
Şekil 3. 14. 1D-LBPmin, 1D-LBPmax, 1D-LBPdifMin ve 1D-LBPdifMax operatörlerinin sinyale uygulanması. (A) 1D-LBP5, (B) 1D-LBPmin, (C) 1D-LBP-max, (D) 1D-LBPDifmax, (E) 1D-LBPDifmin.....	68
Şekil 3. 15. 1D-LBP5,1D-LBPmin, 1D-LBPmax, 1D-LBPdifMin ve 1D-LBPdifMax sinyallere ait histogramlar.....	69
Şekil 3. 16. LSTM hücre yapısı	70
Şekil 3. 17. Rulman arıza teşhis diyagramı	72
Şekil 3. 18. Rulman titreşim sinyallerin sınıflandırılması için LSTM ve 1D-CNN tabanlı hibrit model.....	73
Şekil 3. 19. 1D-TP yöntemin örnek sinyale uygulanması (A) Örnek titreşim işaretleri üzerindeki bir bölüm, (B) işaret değerleri, (C) merkez değerin(Pc) komşu değerler (Pi) ile karşılaştırılması, (D) Upper ve Lower değerlerin ayrıştırılması (E) ikili dizgelerin onlu değerlere dönüştürülmesi.....	74
Şekil 3. 20. Farklı β değerlerine göre filtreleme	75
Şekil 3. 21. (A) Örnek bir titreşim sinyali, (B) 1D-TP dönüşümü sonucu elde edilen üst sinyaller, (C) Üst sinyaller histogramı, (D) 1D-TP dönüşümü sonucu elde edilen alt sinyaller, (E) Alt sinyaller histogramı.....	76
Şekil 3. 22. Önerilen yönteme ait blok diyagram.	76
Şekil 4. 1. Her bir entropiye ait başarı oranlarına ait radar grafik	82
Şekil 4. 2. 1D-CNN +LSTM hibrit modelin iki veri seti için karışıklık matrisleri	86
Şekil 4. 3. 1D-CNN+LSTM hibrit modelin performans ve kayıp grafikleri	87
Şekil 4. 4. Bearing1_3 için uyum ve hata grafikleri	92
Şekil 4. 5. Bearing2_3 için uyum ve hata grafikleri	93
Şekil 4. 6. Bearing3_3 için uyum ve hata grafikleri	93
Şekil 4. 7. Bearing1_3, Bearing2_3 ve Bearing3_3 için Score grafikler.....	94
Şekil 4. 8. β parametresinin farklı değerleri için RMSE ve Score değerleri.....	96

SİMGELER VE KISALTMALAR

Simgeler

N	: Zaman serisindeki toplam veri noktası sayısı
m	: Faz uzayının gömülü boyutu
r	: Gecikme değeri
R	: Benzerlik yarıçapı
$Y_{1:N}$	: Gecikmeli yeniden yapılandırılmış vektör
N_i	: Belirli bir hedef noktada verilen komşu noktaların sayısı
Φ_m	: Yaklaşık entropi için düzenlilik ölçütü
$u_0(i)$	: Bir m - boyutlu vektörün ortalama değeri
$\phi(n, r)$	: Belirli bir n gradyan ve r genişlik için benzerlik ölçütü
X_i	: Zaman serisinin i . örneğini ifade eder.
L	: Zaman serisinin toplam uzunluğu.
θ	: Heaviside fonksiyonu.
$x(t)$	: Zaman alanındaki sinyal
H	: Güç spektral entropisi
M	: Histogramın kutu sayısı
Ω	: Tanımlanan anahtar örüntü

Kısaltmalar


1D-CNN	: Bir Boyutlu Evrişimli Sinir Ağı
1D-TP	: Bir Boyutlu Üçlü Desen
ANN	: Yapay Sinir Ağı
ASB	: Uyarlanabilir Bir Eğim Bloğu
AVMD	: Uyarlamalı Parametre Optimizasyonlu Varyasyonel Mod Ayırıştırma
AWPSO-ELM	: Uyarlamalı Ağırlık Parçacık Sürü Optimizasyonu ile Optimize Edilmiş
Aşırı Öğrenme Makinesi	
BFD	: Rulman Arıza Tespiti
BP	: Geriye Yayılım
BPNN	: Geriye Yayılım Sinir Ağları
BS	: Bilya Boyutu
CBAM	: Evrişimsel Blok Dikkat Modülü
CDBN	: Evrişimsel Derin İnanç Ağı
CMPE	: Bileşik Çok Ölçekli Permütasyon Entropisi
CNN	: Evrişimli Sinir Ağları
CSDAE	: Sıkıştırılmış Algılama Derin Otomatik Kodlayıcı
CWRU	: Case Western Reserve Üniversitesi
CWT	: Sürekli Dalga Dönüşümü
DAE	: Derin Otomatik Kodlayıcı
DANN	: Sinir Ağlarının Alan-Çekişmeli Eğitimi
DCMADA	: Derin Evrişimselli Çoklu-Ters etki alanı Adaptasyonu
DFDTLN	: Derin Özellik Ayırıştırma Transfer Öğrenme Ağı
DL	: Derin Öğrenme
DNN	: Derin Sinir Ağı
DNN-MSFE	: Derin Sinir Ağı ve Çok Ölçekli Bulanık Entropi

DRSN	: Derin Artık Büzülme Ağı
DSCN	: Derin Ayrılabilir Evrişimsel Ağı
ELM	: Aşırı Öğrenme Makinesi
ELU	: Üstel Doğrusal Birim
EM	: Beklenti Maksimizasyonu
FBCL	: Özellik Artırmaya Dayalı Sürekli Öğrenme
FELM	: Geri Beslemeli Bir Aşırı Öğrenme Makinesi
FFT	: Hızlı Fourier Dönüşümü
FN	: Yanlış Negatif
FOSC	: Arıza Sırası Spektrum Dönüşümü
FP	: Yanlış Pozitif
FPT	: İlk Tahmin Zamanı
GAN	: Üretici Çekişmeli Ağ
GA-SVR	: Genetik Algoritma-Destek Vektör Regresyonu
GLMMD	: Grafik Laplasyen Düzenlenmiş Maksimum Ortalama Tutarsızlık
HI	: Sağlık Göstergesi
I-1DCNN	: Geliştirilmiş Tek Boyutlu Evrişimsel Sinir Ağı
IDRSN	: Geliştirilmiş Bir Derin Artık Büzülme Ağı
IL-MTSC	: Artımlı Öğrenme Tabanlı Çok Görevli Paylaşımlı Sınıflandırıcı
IPSTF	: Geliştirilmiş Yapay Yumuşak Eşik Fonksiyonu
IR	: İç Bilezik
MA	: Hareketli Ortalama
MADMMDL	: Çok Ölçekli Alternatif Yön Çarpanı Yöntemi ile Sözlük Öğrenimi
MAE	: Ortalama Mutlak Hata
MCNN	: Çok Kanallı Evrişimsel Sinir Ağı
MD	: Mahalanobis Mesafesi
MFELM	: Çok Değişkenli Geri Beslemeli Aşırı Öğrenme Makinesi
MGGCN	: Çok Katmanlı Çapraz Alanlı Kapılı Grafik Evrişim Ağı
MHI	: Modifiye Sağlık Göstergesi
MK-MMD	: Birden Fazla Çekirdek Maksimum Ortalama Farklılık
MK-MMD	: Çoklu Çekirdek Maksimum Ortalama Tutarsızlığı
MM-1D-LBP	: Min Max Bir Boyutlu Yerel İkili Desen
MOMEDA	: Çok Noktalı Optimal Minimum Entropi Düzeltilmiş Dekonvolüsyon
MSCF	: Çok Ölçekli Kırpma Füzyonu
MSCNN	: Çok Ölçekli evrişimsel Sinir Ağı
NLP	: Doğal Dil İşleme
OR	: Dış Bilezik
PSLOC	: Tahminsel Kaydırmalı Yerel Aykırı Değer Düzeltmesi
PSO	: Parçacık Sürü Optimizasyonu
PSTB	: Pseudo-Yumuşak Eşikleme Bloğu
RA	: Göreceli Doğruluk
RCP	: Yeniden Yapılandırma Doğruluğu
RMSE	: Kök Ortalama Kare Hata
RPCMMFE	: Rafine Edilmiş Parçalı Bileşik Çok Değişkenli Çok Ölçekli Bulanık Entropi
RPM	: Dakikadaki Devir Sayısı
RRMS	: Göreceli Kök Ortalama Kare
RUL	: Kalan Kullanım Ömrü
SAE	: Yığılmış Otomatik Kodlayıcı
SBiLSTM	: İki Yönlü Yığılmış Uzun Kısa Süreli Bellek Ağı

SCR	: Durum Değişim Hızı
SDP	: Simetrik Nokta Deseni
SMAPE	: Simetrik Ortalama Yüzde Hata
SNR	: Sinyal-Gürültü Oranı
SPC	: İstatistiksel Süreç Kontrolü
SPC	: Spektral Çapraz Korelasyon Derecesi
STFT	: Kısa Süreli Fourier Dönüşümü
STFT	: Kısa Zamanlı Fourier Dönüşümü
SVM	: Destek Vektör Makineleri
TCNN	: Transfer Evrişimsel Sinir Ağı
TEOD	: Teager Enerji Operatörü Demodülasyonu
TL	: Transfer Öğrenme
TMLP	: Aktarılabılır Çok Katmanlı Algılayıcı
TN	: Doğru Negatif
TP	: Doğru Pozitif
TSP	: Tahmin Başlangıç Zamanı
VAF	: Titreşim ve Akustik Birleşme
VMD-SVD	: Varyasyonel Mod Ayrıştırma-Tekil Değer Ayrıştırma
VME	: Varyasyonel Mod Çıkarımı
WDCNN	: Geniş Derin Evrişimli Sinir Ağı
YÜD	: Yerel Üçlü Desenler

1. GİRİŞ

Rulmanlar, döner hareketlerin verimli bir şekilde iletilmesini sağlayan, sürtünmeyi minimuma indirerek mekanik sistemlerin performansını ve ömrünü artıran kritik bileşenlerdir. Genellikle iki yüzey arasındaki sürtünmeyi azaltmak amacıyla kullanılan bu bileşenler, makine mühendisliği ve endüstriyel uygulamalarda önemli bir yer tutar. Rulmanlar, temel olarak iç ve dış halkalar, yuvarlanan elemanlar (bilyalar veya makaralar) ve bu elemanları hizalayan bir kafesten oluşur. Bu yapı, rulmanların yüksek hızlarda çalışabilmesine ve büyük yükleri güvenilir bir şekilde taşıyabilmesine olanak tanır. Rulmanlar, döner ya da lineer hareketli bileşenlerin sürtünmesiz veya düşük sürtünmeyle çalışmasını sağlamak amacıyla kullanılan mekanik parçalar olarak tanımlanabilir. Rulmanların temel işlevi, hareketli parçaların birbirine temas etmesini önleyerek sürtünmeyi azaltmak ve enerji kayıplarını minimize etmektir. Genellikle iki ana bileşenden oluşur: sabit bir dış halka ve dönen bir iç halka. Bu halkaların arasında yer alan yuvarlanma elemanları, sürtünmeyi azaltarak hareketin verimli bir şekilde iletilmesini sağlar. Kafes adı verilen kısım ise, yuvarlanma elemanlarının düzgün bir şekilde hizalanmasını ve hareket etmesini sağlar. Genel amaçlı kullanılan bir rulmanın görüntüsü Şekil 1.1.'de verilmiştir (Kaya ve ark., 2021; Zhuang ve ark., 2022).



Şekil 1.1. Bir rulmanın elemanları (Rastegari, A. 2017)

Rulmanlar, yoğun mekanik stres altında olduklarından dolayı yüksek dayanıklılığa sahip olmalıdır. Rulmanlarda meydana gelen hasarlar, sistemi olumsuz etkileyebilir ve

otomasyon sistemlerinde büyük maddi kayıplara ve hatta insan kayıplarına neden olabilir. Makinelerin sorunsuz çalışması ve uzun ömürlü olması için rulman bileşenlerinin hatasız bir şekilde çalışması hayati önem taşır. Bu nedenle, döner rulmanların arıza teşhisi yapılması, bakım maliyetlerini azaltmak ve mekanik sistemlerin güvenilirliği ile güvenliğini artırmak açısından büyük bir öneme sahiptir. Avrupa'daki bir çalışmaya göre, rulmanların %34'ü ömrünü tamamlayabilirken %66'sı çeşitli nedenlerden dolayı önceden değiştirilmiştir. Erken değiştirilenler arasında, %16'sının montaj ve sökme hataları nedeniyle ömrünü tamamlayamadığı, %36'sının yağlama hataları nedeniyle ömrünü tamamlayamadığı ve %14'ünün kötü çalışma koşulları ve kirlilik nedeniyle ömrünü tamamlayamadığı görülmüştür. Bu nedenle, uygun bakım ve yağlama prosedürlerinin düzenli olarak uygulanması büyük önem taşır. Rulman arızaları, mekanik sürtünme, aşırı ısınma, aşırı veya ters yükleme ve işletme sırasında kirlenme gibi çeşitli faktörlerden kaynaklanabilir. Ayrıca, üretim sırasında bilyelerin hizalamasındaki hatalar ve dayanıksız malzemelerin kullanımı da rulmanlardaki arızalara neden olabilir. Bu tür hatalar, rulmanlara dayanan makinelerin performansını önemli ölçüde etkileyebilir. Rulman arızalarının erken tespiti ve gerekli önlemlerin alınması, makinelerin verimli bir şekilde çalışmasını sağlamak için kritik bir öneme sahiptir. Mekanik iletim sistemlerinin temel bir bileşeni olarak, rulman arızaları mekanizmanın kararlılığı, hassasiyeti ve verimliliği üzerinde büyük etkilere sahip olabilir. İlk başta hafif arızaların bile ihmal edilmesi ve kötüleşmesine izin verilmesi, mekanizmanın güvenliği ve ömrüne tehdit oluşturabilir. Bu nedenle, rulmanlar, tüm mekanizma ile karşılaştırıldığında oldukça ucuz oldukları düzenli olarak izlenmeli ve arıza durumunda zamanında değiştirilmelidir. Rulmanların arızası genellikle tüm mekanik sistemlerin güvenli çalışmasını etkiler. İstatistikler, dönen makinelerdeki arızaların yaklaşık %40'ının rulman arızasından kaynaklandığını göstermektedir. Rulmanların değeri belki yüksek olmayabilir, ancak rulman arızaları doğrudan ilgili miller, dişliler ve diğer bileşenleri etkileyerek tüm makine ve ekipmanın normal şekilde çalışmasını engelleyebilir. Bu da ciddi ekonomik kayıplara yol açabilir. Bu nedenle, rulman arızalarının erken tespiti, beklenmedik arızaları ve rulman arızalarından kaynaklanan bakım maliyetlerini önlemek için son derece kritik bir rol oynar (Yu ve ark., 2023; Kaya ve ark., 2022; Chen ve ark., 2021).

Rulmanlar, geniş bir endüstriyel uygulama yelpazesinde kullanılır. Havacılık, uzay ve gemi yapımı tekerlekli taşıtlar, uçaklar, trenler, motorlar, taşıma hatları, dişliler, kalıplar, çamaşır makineleri, mikroskoplar, teleskoplar, rüzgâr türbinleri ve pompalar gibi

birçok mekanizmada rulmanlar geniş bir uygulama alanına sahip olmakla birlikte önemli bir rol oynar. Rulmanların bu kadar geniş bir kullanım alanı bulmasının nedeni, hareketli parçaların sürtünmesini azaltarak sistemlerin verimliliğini artırmalarıdır. Genellikle yüksek hız ve yük altında çalışan sistemlerde kullanılırlar. Bu nedenle, yüksek hassasiyet, güvenilirlik ve dayanıklılık özellikleri taşımaları gereklidir (Kuncan ve ark., 2020; Hou ve ark., 2023).

Rulmanlar, mekanik sistemlerin işleyişinde kritik bir öneme sahiptir. Döner parçaların birbirine temasını engelleyerek aşınmayı ve enerji kaybını minimize ederler. Bu, makinelerin daha uzun ömürlü olmasını ve daha verimli çalışmasını sağlar. Özellikle yüksek hız ve yük altında çalışan sistemlerde, rulmanların dayanıklılığı ve güvenilirliği, tüm sistemin performansını doğrudan etkileyebilir. Rulmanlar tek başlarına yüksek bir maddi değere sahip olmasalar da arızalanmaları, makine sistemlerinde ciddi hasarlara neden olabilir ve bu arızalar büyük maliyetlere yol açabilir (Chen ve ark., 2021; Wang ve ark., 2023).

Rulmanlar, yoğun mekanik stres altında çalıştıkları için zamanla arızalar meydana gelebilir. Rulman arızaları, genellikle aşırı ısınma, aşırı yükleme, kirlilik, yağlama eksiklikleri, montaj hataları ve imalat hataları gibi nedenlerden kaynaklanır. Bu arızalar, rulmanların iç ve dış halkalarında, yuvarlanma elemanlarında veya kafesinde deformasyonlara ve aşınmalara neden olabilir. Rulman arızaları genel olarak dört ana grupta incelenebilir: Yüzey hasarları, malzeme yorgunluğu, korozyon ve kontaminasyon. Yüzey hasarları, yuvarlanma elemanları ile halkalar arasındaki metal-metal temasından kaynaklanır. Bu durum, özellikle yüksek hızlarda ve ağır yüklerde çalışan rulmanlarda yaygındır. Malzeme yorgunluğu, rulmanların sürekli yük altında kalması sonucu meydana gelir ve bu da rulman yüzeyinde çatlakların oluşmasına yol açar. Korozyon, rulman yüzeyinin kimyasal reaksiyonlar sonucu aşınmasıdır ve genellikle nemli veya kirli ortamlarda çalışan rulmanlarda görülür. Kontaminasyon ise rulman içine giren kir, toz veya diğer yabancı maddelerin, rulmanın işleyişini olumsuz etkilemesiyle ortaya çıkar.

Rulman arızalarının yol açtığı zararlar oldukça ciddidir. Mekanik sistemlerin performansında düşüş, verim kaybı, artan enerji tüketimi ve yüksek bakım maliyetleri bu zararların başında gelir. Ayrıca, rulman arızaları, sistemdeki diğer bileşenlerin de hasar görmesine neden olabilir. Örneğin, bir rulmanın arızalanması, ona bağlı olan miller, dişliler veya diğer mekanik parçaların da işlevselliğini olumsuz etkileyebilir. Bu da sistemin tamamen durmasına ve büyük ekonomik kayıplara yol açabilir (Harris & Kotzalas, 2006; Kaya ve ark., 2021; Kuncan, 2020; Kuncan ve ark., 2020).

Rulman arızalarının erken tespiti, sistemin güvenliği ve verimliliği açısından kritik bir öneme sahiptir. Şu anda, rulman arıza teşhisi için en yaygın kullanılan teknik, titreşim verilerini izleyerek nesnenin sağlık durumunu değerlendirmeye dayanan durum izleme teknikleridir. Bu amaçla çeşitli arıza tespit yöntemleri geliştirilmiştir. Titreşim analizi, bu yöntemler arasında en yaygın kullanılanıdır. Titreşim analizi, rulmanların arıza tespiti ve durum izleme süreçlerinde yaygın olarak kullanılan bir tekniktir. Rulmanlar, makine sistemlerinin kritik bileşenleri olup, zamanla aşınma ve yorgunluk gibi nedenlerden dolayı arızalanabilirler. Bu arızaların erken tespiti, makinelerin kesintisiz çalışması ve bakım maliyetlerinin azaltılması açısından büyük önem taşır. Titreşim analizi, bu bağlamda, rulmanların çalışma durumunu izleyerek potansiyel arızaların tespit edilmesinde etkili bir araçtır. Titreşim analizi, bir rulman veya mekanik sistemde meydana gelen titreşimlerin ölçülmesi ve bu titreşimlerin frekans bileşenlerinin analiz edilmesi sürecidir. Titreşimler, rulman içindeki yuvarlanma elemanlarının halkalarla etkileşimi sırasında oluşur. Bu etkileşimler, belirli bir frekans aralığında titreşimler üretir. Bir rulman düzgün çalıştığında, bu titreşimler genellikle düşük seviyelerde ve belirli bir frekans spektrumunda kalır. Ancak, rulman içinde bir arıza meydana geldiğinde, bu titreşimlerin seviyesi ve frekans spektrumu değişir. Hatta rulman sisteminde gürültü veya titreşim de anormal dalgalanmalara neden olabilir. Titreşim analizi, farklı yöntemlerle gerçekleştirilebilir. Bu yöntemlerin başlıcaları şunlardır:

1. **Zaman-Domain Analizi:** Bu yöntem, titreşim verilerinin zamanla nasıl değiştiğini analiz eder. Zaman-domain analizi, titreşim sinyalinin zaman içindeki genliğini doğrudan inceler. Arızalar genellikle titreşim sinyalinde ani değişiklikler veya piklerle kendini gösterir. Bu nedenle, zaman-domain analizi, ani arızaların tespitinde etkili olabilir. Ancak, zaman-domain analizi, sinyalin frekans bileşenlerini belirlemek için yeterli değildir.
2. **Frekans-Domain Analizi:** Bu yöntem, titreşim sinyalinin frekans bileşenlerini analiz eder. Frekans-domain analizinde, genellikle Hızlı Fourier Dönüşümü (Fast Fourier Transform, FFT) kullanılır. FFT, zaman-domain verilerini frekans-domain verilerine dönüştürerek, titreşimlerin hangi frekansta meydana geldiğini belirler. Rulman arızaları, genellikle belirli frekanslarda anormal titreşimler üretir. Bu nedenle, frekans-domain analizi, rulman arızalarının tespitinde yaygın olarak kullanılır. Örneğin, iç halka arızaları, dış halka arızaları, yuvarlanma elemanlarındaki arızalar ve kafes arızaları, belirli frekanslarda karakteristik titreşimler üretir.

3. **Zarf Analizi:** Bu yöntem, zayıf ve düşük frekanslı titreşim sinyallerini güçlendirmek için kullanılır. Zarf analizi, özellikle yuvarlanma elemanlarındaki küçük arızaların tespitinde etkilidir. Bu teknik, sinyalin genlik zarfını belirleyerek, düşük genlikli titreşimleri daha belirgin hale getirir. Rulmanların erken aşama arızaları, genellikle düşük genlikli sinyaller üretir, bu nedenle zarf analizi bu tür arızaların erken tespiti için çok yararlıdır.
4. **Dalgacık Dönüşümü:** Dalgacık dönüşümü (Wavelet Transform), sinyalin hem zaman hem de frekans bileşenlerini inceleyebilen bir tekniktir. Bu yöntem, özellikle zamanla değişen sinyallerin analizinde kullanılır. Dalgacık dönüşümü, rulman arızalarının tespiti için zaman-frekans analizini mümkün kılar, bu da arızaların zamanla nasıl geliştiğini anlamada yardımcı olur. Geleneksel FFT'nin aksine, Dalgacık dönüşümü, sinyalin hem düşük hem de yüksek frekanslı bileşenlerini aynı anda inceleyebilir, bu da rulman arızalarının daha doğru bir şekilde tespit edilmesini sağlar.

Titreşim analizi, çeşitli endüstriyel uygulamalarda yaygın olarak kullanılır. Bu yöntem, özellikle yüksek hızlı makinelerde, türbinlerde, motorlarda, dişli kutularında ve pompalarda rulmanların durum izlenmesi için kritiktir. Bu tür makinelerde, rulman arızalarının erken tespiti, makinelerin duruş sürelerini minimize etmek ve maliyetli hasarları önlemek için hayati öneme sahiptir. Titreşim analizine dayalı bir bakım stratejisi, arızaları tespit ederek, arızaların gelişimini izleyebilir ve önleyici bakım programlarının optimize edilmesine katkıda bulunur. Titreşim analizi, birçok avantaja sahiptir. İlk olarak, rulman arızalarının erken tespiti için son derece hassas bir yöntemdir. Titreşim analizi, küçük arızaların bile tespit edilmesine olanak tanır, bu da makinelerin beklenmedik duruşlarını önler. İkinci olarak, bu yöntem, farklı arıza türlerini (örneğin, iç halka, dış halka, yuvarlanma elemanları ve kafes arızaları) tespit edebilme kapasitesine sahiptir. Üçüncü olarak, titreşim analizi, sürekli izleme ve veri toplama yetenekleri sayesinde, rulmanların durumunu gerçek zamanlı olarak izleyebilir. Ancak, titreşim analizinin bazı dezavantajları da bulunmaktadır. Bu yöntem, gelişmiş veri analizi yetenekleri ve özel ekipman gerektirir, bu da maliyetli olabilir. Ayrıca, sinyalin doğru bir şekilde yorumlanması için uzmanlık gereklidir, aksi takdirde yanlış teşhisler yapılabilir. Örneğin, titreşim sinyalindeki gürültü veya diğer mekanik bileşenlerden gelen titreşimler, rulman arızalarıyla karıştırılabilir. Son olarak, titreşim analizi, yalnızca arızalar belirli bir aşamaya geldiğinde etkili olabilir; bu nedenle, çok erken aşama arızaları tespit etmek her zaman mümkün olmayabilir. Bir rulman arızası meydana geldiğinde, yuvarlanma

elemanları arıza yüzeyi ile temas eder ve rulman sistemi içinde titreşimler oluşur. Bu titreşimler, sinyal işleme teknikleri kullanılarak analiz edilir ve arıza hakkında bilgi edinilir (Randall & Antoni, 2011; Antoni, 2009; Meng ve ark., 2023; Pei ve ark., 2021; Kuncan, 2020; Jin ve ark., 2023; Wang ve ark., 2022; Zou ve ark., 2022).

Son yıllarda, makine öğrenmesi ve derin öğrenme gibi yapay zeka tabanlı yaklaşımlar, rulman arıza tespitinde önemli bir rol oynamaya başlamıştır. Makine öğrenmesi, rulman arıza tespitinde, bilgisayarların geçmiş rulman verilerini analiz ederek arıza belirtilerini öğrenme ve bu öğrendiklerini kullanarak gelecekteki arızaları tahmin etme yeteneği kazanmasını sağlar. Bu süreçte, rulmanlardan elde edilen titreşim, sıcaklık, gürültü gibi veriler kullanılır ve bu veriler üzerinden belirli arıza modelleri oluşturulur. Makine öğrenmesi, bu modelleri kullanarak yeni verilerle karşılaştığında, rulmanın arıza yapıp yapmayacağı konusunda tahminlerde bulunabilir.

Derin öğrenme ise, rulman arıza tespitinde daha karmaşık ve çok katmanlı sinir ağları kullanarak, rulmanlardan elde edilen büyük ve karmaşık veri setlerinden anlamlı özellikler çıkarmayı hedefler. Bu sayede, rulman arızalarının daha ince ayrıntılarını ve karmaşık ilişkilerini yakalayarak, erken arıza tespiti ve daha doğru tahminler yapılabilir. Örneğin, derin öğrenme teknikleri, rulmanlardan gelen çok sayıda sinyalin detaylı analizini yaparak, arızaların başlangıç aşamalarını bile tespit edebilir ve böylece bakım süreçlerinin optimize edilmesine katkıda bulunur. Makine öğrenmesi ve derin öğrenme modelleri, büyük miktarda veri üzerinde eğitim yaparak arıza tespiti için modeller oluşturur. Destek Vektör Makineleri (Support Vector Machine, SVM), Geriye Yayılım Sinir Ağları (Backpropagation Neural Network, BPNN), Evrişimli Sinir Ağları (Convolutional Neural Network, CNN) gibi modeller, rulman arızalarının tespitinde sıklıkla kullanılır. Bu yöntemlerin avantajları arasında, insan hatasını minimize etmesi, yüksek doğruluk sağlaması ve karmaşık veri setlerini işleyebilmesi yer alır. Özellikle derin öğrenme tabanlı modeller, büyük veri setlerinde daha iyi performans gösterir ve arıza tespitinde yüksek hassasiyet sağlar (Hou ve ark., 2022; Wang ve ark., 2021; Yao ve ark., 2022).

Makine öğrenmesi ve derin öğrenme temelli modellerin en büyük avantajı, karmaşık veri setlerinde yüksek doğruluk ve hassasiyetle arıza tespiti yapabilmeleridir. Bu modeller, manuel olarak özellik çıkarma ihtiyacını ortadan kaldırarak, daha az insan müdahalesi ile çalışır. Ayrıca, sürekli öğrenme yetenekleri sayesinde, yeni veri setlerine uyum sağlama ve arıza tespit performansını artırma potansiyeline sahiptirler (Wang ve ark., 2021). Ancak, bu modellerin bazı dezavantajları da vardır. Büyük veri setlerine

ihtiyaç duymaları, eğitim sürecinin uzun ve hesaplama açısından yoğun olması, bu yöntemlerin en büyük zorlukları arasındadır. Ayrıca, derin öğrenme modellerinin açıklanabilirlik ve yorumlanabilirlik açısından sınırlı olması, bazı endüstriyel uygulamalarda güvenilirliklerini azaltabilir. Bu nedenle, bu modellerin uygulanmasında dikkatli bir dengeleme yapılması ve gerektiğinde geleneksel arıza tespit yöntemleri ile birleştirilmesi önemlidir.

Sonuç olarak, rulman arızalarının erken tespiti ve önlenmesi, endüstriyel makinelerin verimliliği, güvenliği ve maliyet etkinliği açısından kritik öneme sahiptir. Makine öğrenmesi ve derin öğrenme gibi modern yaklaşımlar, rulman arıza tespitinde gelecekte daha da yaygınlaşacak ve bu alandaki araştırmaların hızla ilerlemesine katkıda bulunacaktır.

Rulmanlarda bir diğer araştırma alanı rulman ömrünün tahmin edilmesidir. Kalan Kullanım Ömrü (Remaining Useful Life, RUL), bir makine veya bileşenin mevcut çalışma koşullarında ne kadar süre daha işlevsel kalacağını ve arızalanmadan önce ne kadar daha çalışabileceğini belirleyen kritik bir ölçüttür. RUL tahmini, özellikle endüstriyel bakım ve operasyon yönetimi açısından büyük bir öneme sahiptir. Bir makinenin veya bileşenin arızalanmadan önce kalan ömrünün doğru bir şekilde tahmin edilmesi, planlı bakım süreçlerinin optimize edilmesine, maliyetlerin düşürülmesine ve sistemlerin genel güvenilirliğinin artırılmasına olanak tanır. Bu tahmin, beklenmedik arızaların ve üretim duruşlarının önlenmesi için hayati önem taşır, çünkü bu tür duruşlar genellikle büyük ekonomik kayıplara yol açabilir (Kaya ve ark., 2021; Chen ve ark., 2021).

RUL tahmininin önemini kavramak için, öncelikle makine ve bileşenlerin ömrü boyunca çeşitli nedenlerle performans kaybına uğradığını ve sonunda arızalanabileceğini anlamak gerekir. Bu arızalar, aşınma, yorgunluk, malzeme bozulması gibi nedenlerle oluşabilir ve bu tür süreçlerin önceden tahmin edilmesi, arızaların minimum maliyetle ve maksimum verimlilikle yönetilmesini sağlar. RUL tahmini, bu süreçleri etkili bir şekilde yönetmek için gereken bilgilere dayalı kararlar almayı mümkün kılar. Özellikle rulmanlar gibi sürekli olarak yüksek stres altında çalışan bileşenler için RUL tahmini, güvenilirliğin artırılması ve bakım maliyetlerinin optimize edilmesi açısından kritik bir rol oynar (Kuncan, 2020; Jin ve ark., 2023). RUL tahmini, birçok farklı endüstride yaygın olarak kullanılır. Özellikle havacılık, otomotiv, enerji üretimi, imalat ve ağır sanayi gibi alanlarda, makinelerin kesintisiz ve güvenli bir şekilde çalışmasını sağlamak için RUL tahminine büyük önem verilir. Örneğin, bir uçak motorunun RUL'u doğru bir şekilde

tahmin edildiğinde, motorun ne zaman bakıma alınması gerektiği önceden planlanabilir ve böylece uçuş güvenliği artırılırken maliyetler de optimize edilebilir. Aynı şekilde, enerji üretim tesislerinde kullanılan türbinler ve jeneratörler için RUL tahmini, sistem güvenilirliğinin korunması ve plansız duruşların önlenmesi açısından kritik bir araçtır (Kaya ve ark., 2021; Wang ve ark., 2021).

RUL tahmini için kullanılan yaklaşımlar, genellikle veri tabanlı ve model tabanlı olmak üzere iki ana kategoriye ayrılır. Veri tabanlı yaklaşımlar, geçmiş çalışma verilerine dayalı olarak arıza olasılığını tahmin eden istatistiksel ve makine öğrenmesi yöntemlerini içerir. Bu yöntemler, genellikle büyük veri setlerine ihtiyaç duyar ve karmaşık algoritmalar kullanarak gelecekteki arızaları tahmin eder. Model tabanlı yaklaşımlar ise, fiziksel sistemlerin dinamik modellerini kullanarak arıza süreçlerini simüle eder ve bu simülasyonlar üzerinden RUL tahmini yapar. Her iki yaklaşımın da kendi avantajları ve dezavantajları bulunmaktadır (Pei ve ark., 2021; Yao ve ark., 2022). Literatüre bakıldığında RUL için farklı yaklaşımların olduğu görülmüştür. Veri tabanlı yaklaşımlar, büyük miktarda tarihsel veriye dayanarak RUL tahmini yapar. Bu yöntemler, makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak, rulmanlar gibi bileşenlerin performansındaki değişiklikleri analiz eder ve bu veriler üzerinden kalan ömrü tahmin eder. Veri tabanlı yaklaşımlar, genellikle hızlı sonuçlar sağlar ve gerçek zamanlı izleme sistemleriyle entegre edilebilir. Ancak, bu yöntemlerin doğru sonuçlar verebilmesi için büyük miktarda kaliteli verilere ihtiyaç duyulur ve veri eksikliği durumunda performansları düşebilir. Ayrıca, bu yöntemler genellikle mevcut verilere dayalı tahminler yapar, bu nedenle yeni veya beklenmedik arıza modlarını tanımlamakta zorlanabilirler (Hou ve ark., 2022; Wang ve ark., 2021). Model tabanlı yaklaşımlar, fiziksel sistemlerin matematiksel modellerini kullanarak arıza süreçlerini simüle eder. Bu yaklaşımlar, bileşenlerin fiziksel özelliklerine ve çalışma koşullarına dayalı olarak, arızaların nasıl gelişeceğini tahmin eder. Model tabanlı yaklaşımlar, genellikle daha az veri gerektirir ve arıza süreçlerinin daha derinlemesine anlaşılmasını sağlar. Ancak, bu yöntemler, sistemlerin karmaşıklığı arttıkça daha zor ve zaman alıcı hale gelebilir. Ayrıca, bu modellerin doğruluğu, kullanılan fiziksel modelin doğruluğuna bağlıdır ve karmaşık sistemler için bu modellerin oluşturulması zor olabilir (Kuncan, 2020; Chen ve ark., 2021). Makine öğrenmesi ve derin öğrenme teknikleri, son yıllarda RUL tahmininde giderek daha fazla kullanılmaktadır. Makine öğrenmesi, tarihsel verilere dayalı olarak gelecekteki arızaları tahmin etmek için algoritmalar geliştirmeye odaklanır. Derin öğrenme ise, daha karmaşık ve çok katmanlı sinir ağları kullanarak büyük veri setlerinden

anlamlı özellikler çıkarmayı hedefler. Bu teknikler, özellikle karmaşık ve büyük veri setlerinde son derece başarılı tahminler yapabilir ve yeni arıza modlarının tanımlanmasında etkilidir. Ancak, bu yöntemler genellikle büyük miktarda veri ve yüksek hesaplama gücü gerektirir. Ayrıca, bu modellerin eğitimi zaman alıcı olabilir ve yanlış verilerle eğitildiğinde yanlış tahminler yapabilir (Yao ve ark., 2022; Jin ve ark., 2023).

Sonuç olarak, RUL tahmini, makinelerin ve bileşenlerin güvenilirliğini artırmak, bakım süreçlerini optimize etmek ve maliyetleri düşürmek için kritik bir araçtır. Veri tabanlı ve model tabanlı yaklaşımlar, farklı avantajlar ve dezavantajlar sunar ve hangi yaklaşımın kullanılacağı, sistemin karmaşıklığı, veri mevcudiyeti ve bakım hedeflerine bağlı olarak değişir. Makine öğrenmesi ve derin öğrenme gibi modern teknikler, RUL tahmininde giderek daha fazla kullanılmakta ve bu alanda önemli ilerlemeler sağlamaktadır. Ancak, bu tekniklerin başarılı bir şekilde uygulanabilmesi için doğru verilerin ve uygun modellerin seçilmesi hayati önem taşır (Kaya ve ark. 2021; Wang ve ark., 2021).

Bu tez çalışmasında rulman arızaların tespiti ve rulman ömrünün tahmini için yeni yaklaşımları önerilmiştir. Farklı senaryolarda oluşturulmuş veri setleri için derin öğrenme ve makine öğrenmesi yaklaşımlar ile rulman arızalarının tespiti gerçekleştirilmiştir. Birinci rulman arızası tespiti yaklaşımında, kurulan bir rulman deney düzeneğinden, belirlenen özel boyutlarda yapay hatalar oluşturulmuş rulmanlardan titreşim sinyalleri toplanmıştır. Titreşim sinyallerinin sınıflandırılması için 3 farklı senaryo için denemeler gerçekleştirilmiştir. Deney 1 (Veri seti 1) farklı hızlarda elde edilen rulman titreşim işaretlerinden (1500, 1740, 1800, 1860 ve 2100), Deney 2 (Veri set 2) için farklı arıza türlerine (Inner Ring, Outer Ring, Ball) sahip titreşim işaretlerinden, Deney 3 (Veri seti 3) ise aynı hız altında farklı boyutlarda (0.15cm, 0.5cm, 0.9 cm) hataya sahip olan rulman titreşim işaretlerinden oluşturulmuştur. Tüm deneyler için rulman titreşim işaretlerinden öznitelik çıkarımı için 18 farklı entropi özneliği (Yaklaşık Entropi (ApEn), Örnek Entropi (SampEn), Bulanık Entropi (FuzzyEn), Kolmogorov Entropisi (K2En), Kenar Permütasyon Entropisi (PermEn), Dağılım Entropisi (DispEn), Koşullu Entropi (CondEn), Güç Spektrumu Entropisi (SpecEn), Dağılım Entropisi (DistEn), Sembolik Dinamik Entropi (SyDyEn), Artış Entropisi (IncrEn), Kosinüs Benzerlik Entropisi (CosiEn), Faz Entropisi (PhasEn), Eğim Entropisi (SlopEn), Izgaralı Dağılım Entropisi (GridEn), Baloncuk Entropisi (BubbEn), Entropinin Entropisi (EnofEn), Dikkat Entropisi (AttnEn)) çıkarılmıştır. Elde edilen entropi öznelikleri geliştirilen Aşırı Öğrenme Makinası (Extreme Learning Machine, ELM) modeline giriş olarak kullanılmıştır.

Özniteliklerin hepsi kullanılarak gerçekleştirilen deneyde yüksek oranda doğruluk elde edilmiştir.

İkinci bir çalışmada rulman titreşim sinyallerden arıza tespiti için yeni bir yaklaşım önerilmiştir. Titreşim sinyallerinden öncelikle sinyal üzerindeki yerel değişimleri dikkate alan bir öznitelik çıkarım yöntemi geliştirilmiştir. Daha sonra MM-1D-LBP ile elde edilen öznitelikler kullanılarak Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM) ve 1 Boyutlu Evrişimli Sinir Ağı (1-Dimensional Convolutional Neural Network, 1D-CNN) tabanlı hibrit bir derin öğrenme ağı ile teşhis işlemi gerçekleştirilmiştir. Önerilen yaklaşımı test etmek için kurulan gerçek bir rulman düzeneğinden elde edilen iki veri seti üzerinde denemeler gerçekleştirildi. Birinci veri seti ile farklı arıza türleri (Inner Ring, Outer Ring, Ball) tahmin edilmeye çalışılmıştır. İkinci veri setinde ise aynı hız altında farklı boyutlarda (0.15cm, 0.5cm, 0.9cm) hataya sahip olan rulman titreşim sinyalleri ile hata boyutu tahmin edilmiştir. İki veri seti için yüksek başarı oranları elde edilmiştir. Elde edilen sonuçlara göre önerilen MM-1D-LBP+1D-CNN-LSTM ile yüksek sonuçlar gözlenmiştir. Önerilen yaklaşımın farklı sinyal grupların sınıflandırılmasında da kullanılabileceği öngörülmektedir.

Bu tez çalışmasının diğer bir aşamasında rulman ömrü tahmini için yeni bir yaklaşım önerilmiştir. Veriye dayalı prognostik teknikler, yüksek hızlı rulmanların kalan kullanım ömrünü (RUL) doğru bir şekilde tahmin etmek için yaygın olarak kullanılmaktalar. Doğru RUL tahmini, rulman bozulma durumu ile mevcut sağlık durumu arasındaki temel ilişkinin belirlenmesine bağlıdır. Rulman kalan ömrünü doğru bir şekilde tahmin etmek için rulmanlardan çıkarılan özniteliklerin etkinliğine bağlıdır. Bu çalışmada rulman kalan ömrünü doğru tahmin etmek için yeni bir yaklaşım önerilmiştir. Rulman titreşim işaretlerine uygulanan 1D-TP metodu sonucunda elde edilen kullanılarak LSTM ile tahmin gerçekleştirilmiştir. 1D-TP titreşim işaretlerine uygulandığında düşük (Lower) ve yüksek (Upper) şeklinde iki farklı öznitelik vektörü oluşmaktadır. Önerilen yaklaşımın etkinliğini test etmek için PRONOSTIA platformundan alınan veri kümesine uygulanmıştır. Performans ölçütleri olarak Ortalama Mutlak Hata (Mean Absolute Error, MAE), Kök Ortalama Kare Hata (Root Mean Square Error, RMSE), Simetrik Ortalama Yüzde Hata (Symmetric Mean Absolute Percentage Error, SMAPE), Bağıl Mutlak Hata (Relative Absolute Error, RA) ve Score kullanılmıştır. Elde edilen sonuçlara göre 1D-TP+LSTM ile rulman kalan ömürlerinin başarılı bir şekilde tahmin ettiği görülmüştür. Sonuç olarak, doğru bir RUL değerlendirmesi veya güvenilirlik analizi, çalışanların

uygun bakım kararları vermesini, mekanik ekipman hasarından kaynaklanan kayıpları ve mal hasarını önlemesini ve üretim güvenliğini iyileştirmesini sağlayacaktır.



2. KAYNAK ARAŞTIRMASI

Literatürde rulman arızalarının tespiti (Bearing Fault Detection, BFD) ve rulman kalan kullanım ömrü tahmini (Remaining Useful Life, RUL) konusunda çeşitli yöntemler geliştirilmiştir. Geleneksel model tabanlı yaklaşımların yanı sıra, özellikle son yıllarda veri tabanlı yöntemler ve yapay zeka uygulamaları bu alanda dikkat çekmektedir. Derin öğrenme, makine öğrenimi, sinyal işleme ve istatistiksel analiz gibi teknikler, rulman arızalarını tespit etmek ve ömrünü tahmin etmek için sıklıkla tercih edilmektedir. Bu bağlamda, literatürdeki çalışmalar BFD ve RUL başlıkları altında ayrı ayrı ele alınmıştır.

2.1. Rulman Arıza Tespiti ile İlgili Literatür Çalışmaları

Chen ve ark. (2021) yaptıkları bu çalışmada, rulman arızalarının erken dönemlerinde zayıf geçici özelliklerin çıkarılmasının zorluğunu ele almışlardır. Geleneksel sözlük öğrenimi yöntemleri, karmaşık sinyallerden arıza özelliklerini çıkarmakta yetersiz kalmakta ve yüksek hesaplama maliyetleriyle karşılaşmaktadır. Bu sorunu çözmek amacıyla, rulman arıza teşhisi için bir arıza darbesi çıkarma ve özellik geliştirme yöntemini önermişlerdir. İlk olarak, rulman titreşim sinyalleri zaman domeninde bölümlere ayrılmış, ardından Çok Ölçekli Alternatif Yön Çarpanı Yöntemi ile Sözlük Öğrenimi (Multi-Scale Alternating Direction Multiplier Method For Dictionary Learning, MADMMDL) kullanılarak, bu segmentlerden arıza darbesi sinyalleri çıkarılmıştır. Son olarak, rulman arıza frekansını güçlendirmek amacıyla frekans spektrumu ortalaması kullanılmıştır. Yöntemin uygulanabilirliği, sayısal simülasyonlar ve raylı sistem arıza simülasyonları ile doğrulamışlardır. Bu çalışmanın sonuçları, karmaşık çalışma koşulları altında rulman arızalarının erken dönem zayıf arıza özelliklerini başarıyla tespit edebildiğini göstermişlerdir. Ancak, yöntemin endüstriyel uygulamalarda yaygın kullanımını sınırlayan en büyük sorun, parametrelerin sinyale ve deneyime dayalı olarak ayarlanması gerekliliğidir. Gelecekteki çalışmalarda, yönteme uyarlanabilir bir fonksiyon eklenmesini de önermektedirler (Chen ve ark.,2021).

Zhang ve ark. (2021) yaptıkları çalışmada, rulman arıza teşhisinde derin öğrenme (Deep Learning, DL) algoritmalarının performansını artırmayı hedeflemişlerdir. Geleneksel aktivasyon fonksiyonlarının, sabit matematiksel formüller kullanarak doğrusal olmayan özellik dönüşümünü gerçekleştirdiği ve bu durumun arıza teşhis

performansını olumsuz etkilediği tespit etmişlerdir. Bu sorunu çözmek amacıyla, eğitim ve eşik adaptif aktivasyon fonksiyonuna sahip tanh fonksiyonu (STAC-tanh) önermişlerdir. Bu yöntem, aktivasyon fonksiyonunun şeklini otomatik olarak ayarlayarak, doğrusal olmayan özellik dönüşümü ile giriş sinyali arasındaki ilişkiyi kurmaktadır. STAC-tanh, ResNet ile birleştirilerek rulman arıza teşhisi için ResNet-STAC-tanh modelini önermişlerdir. İki rulman veri seti üzerinde yapılan deneylerde, STAC-tanh fonksiyonunun eklenmesiyle modelin ortalama doğruluk oranı sırasıyla %90.00 ve %90.77'ye ulaşmıştır. Geleneksel aktivasyon fonksiyonları ile karşılaştırıldığında, bu yeni yöntem motor sabit hız ve zaman değişkenli hız deneylerinde %6.32'ye kadar daha yüksek sınıflandırma doğruluğu sağlamıştır. Ancak, modelin farklı çalışma koşullarında genelleme yeteneğinin sınırlı olduğu ve STAC-tanh fonksiyonunun eklenmesiyle eğitim sürecinin zaman alıcı hale geldiğini belirtmişlerdir (Zhang ve ark., 2021).

Wang ve ark. (2021) yaptıkları çalışmada, tek modlu sensör sinyallerinin yetersiz doğruluk sağladığı ve gürültüye karşı savunmasız olduğu rulman arıza teşhisi sorununa çözüm olarak, çok modlu sensör sinyallerinin birleşimi önermişlerdir. Titreşim sinyalleri ve akustik sinyaller ivmeölçer ve mikrofon kullanılarak toplanmış, ardından bu sinyaller Bir boyutlu evrişimsel sinir ağı (One-Dimensional Convolutional Neural Network, 1D-CNN) tabanlı Titreşim ve Akustik Birleşme (Vibration and Acoustic Fusion, VAF) algoritması ile birleştirilmiştir. Deneylerde, on farklı rulman grubundan elde edilen veriler kullanılarak yöntem test edilmiş ve düşük sinyal-gürültü oranlarında (Signal-to-Noise Ratio, SNR) bile önerilen yöntemin tek modlu sensör tabanlı algoritmalarından daha yüksek teşhis doğruluğu sağladığını göstermişlerdir. Örneğin, "SNR = -6 dB" koşulunda 1D-CNN tabanlı VAF algoritması %99.33 doğruluk sağlarken, sadece titreşim ve sadece akustik sinyallerle sırasıyla %96.52 ve %94.04 doğruluk oranlarına ulaşmışlardır. Diğer algoritmalar ise Geniş Derin Evrişimli Sinir Ağı (Wide Deep Convolutional Neural Network, WDCNN) %86.20, Hızlı Fourier Dönüşümü - Yığılmış Otomatik Kodlayıcı (Fast Fourier Transform - Stacked Autoencoder, FFT-SAE) %85.64, Hızlı Fourier Dönüşümü - Geriye Yayılım (Fast Fourier Transform-Backpropagation, FFT-BP) %81.09, destek vektör makineleri (support vector machines, SVM) ise %62.14 doğruluk oranları sağlamıştır. Sonuçlar, özellikle düşük Sinyal-Gürültü Oranı (Signal-to-Noise Ratio, SNR) koşullarında titreşim ve akustik sinyallerin tamamlayıcı özelliklerinin birleştirilmesinin teşhis başarısını artırdığını göstermişlerdir (Wang ve ark., 2021).

Bir diğerk çalışmada Bai ve ark. (2021), makine arıza teşhisinde derin öğrenmenin sınırlamalarını aşmayı hedefleyen yeni bir strateji sunmuşlardır. Özellikle, sınırlı sensör verisi ve değişken çalışma koşulları altında rulman arıza teşhisini iyileştirmek için geliştirilen bu yöntem, Çok Kanallı Evrişimsel Sinir Ağı (Multi-channel Convolution Neural Network, MCNN) ile Çok Ölçekli Kırpma Füzyonu (Multi Scale Clipping Fusion, MSCF) veri artırma tekniğini birleştirmişlerdir. Çalışmada, arıza sinyalleri önce MSCF ile dört farklı ölçeğe genişletilmiş ve ardından Kısa Süreli Fourier Dönüşümü (Short-Time Fourier Transform, STFT) kullanılarak zaman-frekans görüntülerine dönüştürülmüştür. Bu çoklu sensörden elde edilen görüntü verileri, öznitelik çıkarma ve arıza deseni sınıflandırması için MCNN aracılığıyla birleştirilmiştir. İki farklı veri seti üzerinde gerçekleştirilen deneyler, MSCF ve MCNN kombinasyonunun her bir sensör kaydındaki bilgiyi en iyi şekilde kullanarak arıza türü sınıflandırma doğruluğunu ve kümeleme etkisini önemli ölçüde artırdığını göstermişlerdir. Birinci veri setinde, sınırlı örnek boyutu ve değişken çalışma koşullarının neden olduğu Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) performansındaki düşüşlerin MSCF veri artırma ile hafifletilebildiğini kanıtlamışlardır. Ayrıca, doğruluk, karışıklık matrisi ve kümeleme analizi sonuçları, çok kanallı CNN'nin veri bütünlüğünü tam anlamıyla kullanarak aşırı öğrenme riskini bastırdığını ve CNN performansını daha da artırdığını göstermişlerdir. İkinci veri seti üzerinde ise benzer sonuçlar elde edilmiş, ancak değişken çalışma koşulları altında test yapılmamış ve veri setinin doğal olarak yüksek kalitesi ve daha az heterojenliği nedeniyle yalnızca küçük bir iyileşme sağlamışlardır. Sonuç olarak, MSCF veri artırma ve MCNN tekniğinin birleştirilmesi, çoklu sensör verilerini en iyi şekilde değerlendirerek veri heterojenliğinin etkisini hafifletmekte ve CNN'nin sınıflandırma görevlerindeki performansını artırmaktadırlar. Bu yaklaşım ile özellikle sınırlı sensör verisi ve değişken çalışma koşulları durumlarında rulman arıza teşhisi için düşük karmaşıklıkta, ancak etkili ve sağlam bir çözüm sunmuşlardır (Bai ve ark., 2021).

Han ve ark. (2021) yaptıkları çalışmada, küçük örnek veri setleriyle kompleks modellerin eğitiminde karşılaşılan zorlukları aşmak amacıyla, Evrişimsel Sinir Ağı (Convolutional Neural Network, CNN) ile Destek Vektör Makinesi'ni (Support Vector Machine, SVM) birleştiren bir sistem önermişlerdir. CNN-SVM sistemi, rulman arıza teşhisinde uygulanmış olup, rulman titreşim verilerinin zaman domain diyagramını sistem girişi olarak kullanmışlardır. CNN, bu verilerden özellikleri çıkarırken, SVM ise nihai rulman arıza tahminini gerçekleştirmiştir. Çalışmanın en büyük katkılarından biri, CNN'den SVM'ye otomatik geçişi sağlayan üç farklı koşulun sisteme eklenmesidir.

Deney sonuçları, bu sistemin daha az zaman tüketimi, yüksek hassasiyet ve güçlü genelleme yeteneği gibi avantajlara sahip olduğunu göstermişlerdir. Özellikle, modelin zaman tüketiminin CNN'in 1/3'ü kadar olduğu, eğitim setinde %100 ve test setinde %99.44 doğruluğa ulaştığı belirlenmiştir (Han ve ark., 2021).

Wan ve ark. (2022) yaptıkları çalışmada, geleneksel rulman arıza teşhis yöntemlerinin farklı çalışma koşulları altındaki yetersizliklerini aşmak için yeni bir Derin Evrişimselli Çoklu-Ters etki alanı Adaptasyonu (Deep Convolution Multi-Adversarial Domain Adaptation, DCMADA) modeli önermişlerdir. Model, üç ana bileşenden oluşmaktadır: özellik çıkarım modülü, alan adaptasyon modülü ve arıza tanı modülü. Özellik çıkarım modülünde, ham titreşim sinyallerinden aktarılabılır ve arıza ayırt edici özellikleri çıkaran geliştirilmiş bir tek boyutlu ResNet derin özellik çıkarıcı kullanılmıştır. Alan adaptasyon modülünde, Çoklu Çekirdek Maksimum Ortalama Tutarsızlığı (Multi-Kernel Maximum Mean Discrepancy, MK-MMD) ve birden fazla alan ayırt edici ile kaynak ve hedef alanlar arasındaki marjinal ve koşullu dağılımlar düzenlenmiştir. Ayrıca, dinamik bir adaptif faktör kullanılarak bu iki dağılımın göreceli önemi ölçülmüştür. Arıza tanı modülünde, elde edilen alan-bağımsız özellikler kullanılarak çapraz alan arıza teşhisi yapılmaktadır. Yapılan deneyler, farklı çalışma yükleri, ölçüm noktaları ve ekipmanlar arasında modelin üstün aktarım yeteneğine sahip olduğunu göstermiştir. Özellikle, farklı senaryolarda %99.4, %88.39 ve %81.61 doğruluk oranları elde edilmiştir, bu da modelin çapraz alan arıza teşhisinde başarılı olduğunu ortaya koymuşlardır (Wan ve ark., 2022).

Wang ve ark. (2023) yaptıkları çalışmada, çeşitli çalışma koşulları altında rulman arıza teşhisi için Artımlı Öğrenme Tabanlı Çok Görevli Paylaşımlı Sınıflandırıcı (Incremental Learning-Based Multi-Task Shared Classifier, IL-MTSC) önermişlerdir. Rulmanların karmaşık ve zorlu çalışma ortamlarına maruz kalmaları nedeniyle arıza yapma olasılıkları yüksektir. Derin öğrenme tabanlı akıllı arıza teşhis yöntemleri, yüksek performans sergilemelerine rağmen, farklı çalışma koşulları altında yapılan teşhislerde zorluklarla karşılaşmaktadır. Özellikle, farklı koşullarda toplanan test verileriyle modelin öğrenilen bilgileri unutmasına neden olan "felaket unutma" problemi ortaya çıkmaktadır. Bu sorunu çözmek amacıyla geliştirilen IL-MTSC, temel yapı olarak Bir boyutlu evrişimsel sinir ağı (One-Dimensional Convolutional Neural Network, 1D-CNN) modelini kullanmışlardır. Modelin önceki bilgileri koruyabilmesi için bilgi damıtma yöntemi uygulanmış ve farklı senaryolar altında çalışan paylaşımlı bir sınıflandırıcı oluşturmuşlardır. Çalışmada kullanılan üç farklı veri kümesi ile yapılan deneylerde, IL-MTSC yöntemi ile %98.27, %100.00 ve %100.00 doğruluk oranları elde edilmiştir.

Sonuçlar, önerilen yöntemin, değişken çalışma koşulları altında rulman arızalarını başarılı bir şekilde teşhis edebildiğini göstermişlerdir (Wang ve ark., 2023).

Bir diğer çalışmada Wang ve ark. (2021), titreşim sinyallerinin ayrıştırılması ve arıza teşhis doğruluğunu artırmak amacıyla, Uyarlamalı Parametre Optimizasyonlu Varyasyonel Mod Ayrıştırma (Adaptive Variational Mode Decomposition, AVMD) teorisi ve Uyarlamalı Ağırlık Parçacık Sürü Optimizasyonu İle Optimize Edilmiş Aşırı Öğrenme Makinesi (Adaptive Weighted Particle Swarm Optimization- Extreme Learning Machine, AWPSO-ELM) modeli üzerine kurulu bir rulman arıza teşhis yöntemi önermişlerdir. İlk olarak modlar arasında bilgi bütünlüğünü ve karışıklığı azaltmak için Spektral Çapraz Korelasyon Derecesi (Spectrum degree of cross-correlation, SPC) kullanılarak optimal ceza faktörü belirlenmiştir. Ayrıca, yeniden yapılandırılan sinyalin orijinal sinyale olan doğruluğunu garanti altına almak için Yeniden Yapılandırma Doğruluğu (Reconstruction Precision, RCP) kriteri kullanılmıştır. AVMD yöntemi ile elde edilen osilasyon enerjisi, arıza özelliği olarak çıkarılmış ve AWPSO-ELM modeline giriş olarak verilmiştir. Deney sonuçları, AVMD yöntemiyle elde edilen arıza özelliklerinin diğer yöntemlere göre daha belirgin olduğunu ve AWPSO-ELM modelinin test veri setinde %100 doğruluk oranına ulaştığını göstermiştir. Önerilen yöntemin, rulman arıza teşhisinde daha yüksek doğruluk sağladığı ve ELM modelinin optimizasyon ile daha iyi sonuçlar verdiği deneysel olarak kanıtlanmıştır (Wang ve ark., 2021).

Pei ve ark. (2021) yaptıkları çalışmada, rulman arıza teşhisi için geleneksel derin öğrenme (Deep learning, DL) tabanlı yöntemlerin yetersizliklerine çözüm bulmak amacıyla yeni bir akıllı teşhis yöntemi önermişlerdir. Çalışma, gürültülü ve dengesiz veri setlerinin arıza teşhisinde yarattığı zorlukları ele alarak daha etkili ve dayanıklı bir yöntem geliştirmeyi hedeflemektedir. Bu bağlamda, titreşim sinyalleri Teager Enerji Operatörü Demodülasyonu (Teager Energy Operator Demodulation, TEOD) tekniği ile işlenmiş ve uygun demodülasyon çeşitliliklerini seçmek için Parçacık Sürü Optimizasyonu (particle swarm Optimization, PSO) ile birlikte EJB (energy Jarque–Bera) istatistiği kullanılmıştır. Önerilen yöntem, çok ölçekli kaba taneli bir prosedürü entegre eden yeni bir Sıkıştırılmış Algılama Derin Otomatik Kodlayıcı (Compressed Sensing Deep Autoencoder, CSDAE) ile özellik verilerini hiyerarşik olarak birleştirmektedir. CWRU (Case Western Reserve University) rulman veri seti üzerinde yapılan deneylerde, düşük Sinyal-Gürültü Oranı (Signal-to-Noise Ratio, SNR) koşullarında dahi diğer yöntemlere kıyasla yüksek doğruluk (%94.80 ve %88.13) elde edilmiştir. Çalışma,

özellikle gürültü ortamında rulman arıza teşhisinde daha iyi dayanıklılık ve doğruluk sunarak, mevcut teşhis yöntemlerine üstünlük sağlamaktadır (Pei ve ark., 2021).

Liu ve ark. (2020) yaptıkları çalışmada, endüstriyel uygulamalarda rulman arızalarının teşhisi için geliştirilen iyileştirilmiş bir Evrişimsel Derin İnanç Ağı (Convolutional Deep Belief Network, CDBN) tabanlı bir model önermişlerdir. Geleneksel arıza teşhis yöntemleri, titreşim sinyallerinin analizi ve işlenmesine bağlı olup, zengin profesyonel bilgi ve deneyim gerektirir. Ancak, bu yöntemlerle doğru özellik çıkarımı ve arıza teşhisi yapmak zordur. Bu sorunu aşmak için, derin öğrenme yöntemleri kullanılarak otomatik özellik çıkarımı gerçekleştirmişlerdir. Çalışmada, orijinal titreşim sinyalleri, hızlı Fourier dönüşümü ile frekans sinyaline dönüştürülerek modelin girdileri iyileştirilmiştir. Ardından, model eğitimi ve yakınsama hızını artırmak için Adam optimizasyon algoritması kullanılmıştır. Modelin genelleme yeteneğini geliştirmek amacıyla, çok katmanlı özellik füzyon öğrenme yapısını önermişlerdir. Bu yöntem, laboratuvarı üretilen bir rulman titreşim sinyali veri seti üzerinde test edilmiştir. Veri seti, sağlıklı rulmanların yanı sıra farklı türlerde ve boyutlarda dokuz tekli arıza ve üç farklı türde bileşik arıza sinyallerini içermektedir. Deney sonuçları, 0 kN ve 1 kN yüklerinde, önerilen modelin sırasıyla %98.15 ve %96.15 gibi yüksek teşhis doğruluğu sağladığını göstermişlerdir. Bu sonuçlar, modelin geleneksel yığın otomatik kodlayıcı, yapay sinir ağı, derin inanç ağı ve standart CDBN'e kıyasla daha üstün bir performans sergilediğini ortaya koymuşlardır (Liu ve ark.,2020).

Wang ve ark. (2021) yaptıkları çalışmada, döner makinelerin bakımında kritik bir rol oynayan rulman arıza teşhisinin doğruluğunu artırmak amacıyla çok modlu sensör sinyallerini birleştiren yeni bir yöntem sunmuşlardır. Tek modlu sensör sinyallerine dayalı geleneksel teşhis yöntemleri, düşük SNR (Signal-to-Noise Ratio) ortamlarında gürültü tarafından yanıltılabilir ve bu nedenle istenilen teşhis doğruluğunu sağlayamaz. Önerilen yöntem, ivmeölçer ve mikrofon tarafından toplanan titreşim ve akustik sinyalleri Bir Boyutlu Evrişimsel Sinir Ağı (One-Dimensional Convolutional Neural Network, 1D-CNN) tabanlı Titreşim-Akustik Birleşimi (Vibro-Acoustic Fusion, VAF) algoritmasıyla birleştirerek daha doğru ve sağlam rulman arıza teşhisi gerçekleştirmektedir. On farklı rulman grubunda yapılan deneyler, önerilen yöntemin farklı Sinyal-Gürültü Oranı (Signal-to-Noise Ratio, SNR) değerlerinde diğer yöntemlerden daha yüksek teşhis doğruluğu sağladığını göstermiştir. Örneğin, SNR = -6 dB altında, önerilen 1D-CNN tabanlı VAF algoritması %99,33 doğruluğa ulaşırken, yalnızca titreşim sinyallerine dayalı algoritma %96,52, yalnızca akustik sinyallere dayalı algoritma ise %94,04

doğruluk sağlamıştır. Ayrıca, FFT-SAE (Fast Fourier Transform- Stacked Autoencoder), FFT-BP (Fast Fourier Transform - Backpropagation) ve SVM (Support Vector Machine) gibi geleneksel yöntemlerle karşılaştırıldığında, önerilen yöntemin düşük SNR ortamlarında daha üstün performans sağladığını göstermişlerdir (Wang ve ark., 2021).

Bir diğer çalışmada Bai ve ark. (2021), rulman arıza teşhisi için derin öğrenme yöntemlerinin uygulama zorluklarını aşmak amacıyla yenilikçi bir yaklaşım önermişlerdir. Yüksek veri miktarı gereksinimi, derin öğrenme yöntemlerinin kullanımını kısıtlamakta; bu bağlamda, Çok Kanallı Evrişimsel Sinir Ağı (Multi-Channel Convolution Neural Network, MCNN) ve Çok Ölçekli Kırpma Füzyonu (multi-scale clipping fusion, MSCF) veri artırma tekniği kombinasyonu kullanılarak bir çözüm geliştirilmiştir. Çalışmada, ham arıza sinyalleri MSCF ile dört farklı ölçek için artırılmış, bu veriler Kısa Zamanlı Fourier Dönüşümü (Short-Time Fourier Transform, STFT) kullanılarak zaman-frekans spektrumlarına dönüştürülmüş ve çok sensörlü veriler MCNN ile 3D (Three-Dimensional) görüntü hacmi olarak birleştirilmiştir. İki farklı veri seti üzerinde yapılan deneyler, MSCF ve MCNN kombinasyonunun sensör verilerinin içeriklerini etkin bir şekilde kullanarak ve aşırı uyum riskini azaltarak sınıflandırma doğruluğunu önemli ölçüde artırdığını göstermiştir. İlk veri setinde, MSCF veri artırma tekniği kullanılarak doğruluk %99.74'e çıkartılmıştır. İkinci veri setinde ise, değişken çalışma koşulları göz önüne alınmadan yapılan testlerde MCNN performansı benzer şekilde yüksek bulunmuş, doğruluk %100'e ulaşmıştır. Bu sonuçlar, MSCF ve MCNN kombinasyonunun veri heterojenliğinin etkilerini azalttığını ve derin öğrenme tabanlı sınıflandırma görevlerinde yüksek performans sağladığını ortaya koymuştur (Bai ve ark., 2021).

Xu ve ark. (2022) yaptıkları çalışmada, döner makine ekipmanlarının güvenli ve istikrarlı çalışması için kritik öneme sahip olan rulman arıza teşhisi problemine odaklanmışlardır. Özellikle, yeni çalışma koşullarında elde edilen arıza verilerinin eksikliği, teşhis modellerinin kurulmasını engellemektedir. Bu sorunu aşmak amacıyla, çalışma, rulman dinamik modeli ve Üretici Çekişmeli Ağ (Generative Adversarial Network, GAN) ile birleştirilen yenilikçi bir sahte-gerçek veri sentezleme yöntemini önermişlerdir. İlk olarak, farklı koşullarda titreşim verilerini simüle etmek için rulman dinamik modelini oluşturmuşlardır. Ardından, dönüşüm modeli bu simülasyon verileri ile eğitilmiş ve eski koşullardaki gerçek dünya verilerini yeni koşullarda kullanılacak dönüşüm verilerine dönüştürmek için kullanmışlardır. GAN modeli ise hem eski koşullardaki simülasyon ve gerçek dünya verileriyle eğitilmiş hem de yeni koşullardaki

simülasyon ve dönüşüm verileri ile ince ayar yapmıştır. Son aşamada, yeni koşullardaki simülasyon verileri, ince ayar yapılmış GAN modeline girilerek yeni koşullardaki üretilmiş veriler elde edilmiş ve bu verilerle arıza teşhis modeli eğitilmiştir. Önerilen yöntemin performansı, bir rulman veri seti üzerinde yapılan çeşitli karşılaştırmalı deneylerle doğrulanmıştır. Sonuçlar, önerilen yöntemin, yeni koşullarda sıfır atış problemiyle etkili bir şekilde başa çıktığını ve yüksek teşhis performansı sağladığını göstermektedir. Özellikle, önerilen teşhis yöntemi, sıfır atış durumu için çalışma koşulu değişimini, simülasyon-gerçek farkını ve model ince ayarını dikkate alarak, gerçek senaryo teşhisi için etkili bir bilgi sunmaktadır. Deneysel sonuçlar, önerilen yöntemin teşhis doğruluğunun Koşul_1'de denetimli gerçek verilerle eğitim (Training with supervised real data in condition_1, TWSRD_C1), Koşul_2'de denetimli simülasyon verileriyle eğitim (Training with supervised simulation data in condition_2, TWSSD_C2), Arıza Sırası Spektrum Dönüşümü (Fault order spectrum conversion, FOSC) ve GAN'ın parametre aktarımı (Parameter transfer of GAN, PTG) yöntemlerine kıyasla sırasıyla %29, %66, %39 ve %3 oranında iyileştiğini göstermiştir. Bu sonuçlar, önerilen modelin sıfır atış durumunda yeni koşullarda etkili bir şekilde arıza teşhisini başardığını doğrulamışlardır (Xu ve ark., 2022).

Hou ve ark. (2022) yaptıkları çalışmada, döner elemanlı rulmanların akustik sinyallerine dayalı olarak arıza teşhisi için bir yöntem önermişlerdir. Rulman arızalarının erken tespiti ve teşhisi, mekanik sistemlerin güvenilirliğini sağlamak açısından kritik bir öneme sahiptir. Ancak, karmaşık çalışma koşullarında ölçülen akustik sinyaller, güçlü parazitler ve bilinmeyen iletim yolları nedeniyle zayıf arıza sinyalleri içerebilir. Bu sorunu çözmek için, çalışmada seyreklik odaklı Çok Noktalı Optimal Minimum Entropi Düzeltilmiş Dekonvolüsyon (Multipoint Optimal Minimum Entropy Deconvolution Adjusted, MOMEDA) yöntemi önermişlerdir. MOMEDA, iteratif olmayan bir kör dekonvolüsyon yaklaşımıdır ve gürültülü sinyallerden arıza ile ilişkili darbeleri çıkarmakta etkili olduğu kanıtlanmıştır. Ayrıca, Laplace dağılımına dayalı seyrekleştirme işlemi kullanılarak gürültü bileşenleri bastırılmış ve periyodik arıza darbeleri güçlendirilmiştir. Yöntemin geçerliliği hem simüle edilmiş hem de deneysel verilerle test edilmiştir. Çalışma, iç bilezik, dış bilezik, kafes ve çoklu arızaların teşhisinde başarılı sonuçlar elde etmiştir. Önerilen yöntem, mevcut yöntemlerle karşılaştırıldığında daha yüksek performans sergilemiş ve akustik sinyallere dayalı rulman arıza teşhisinde %95'in üzerinde başarı oranı sağlamıştır (Hou ve ark., 2022).

Tong ve ark. (2023) yaptıkları çalışmada, rulman arıza teşhisi sırasında gürültülü ortamlarda sinyal bozulması problemini çözmek için Geliştirilmiş Bir Derin Artık Büzülme Ağı (Improved Deep Residual Shrinkage Network, IDRSN) yöntemini önermişlerdir. Çalışmada, sinyal bozulmasını azaltmak amacıyla, Geliştirilmiş Yapay Yumuşak Eşik Fonksiyonu (Improved Pseudo-Soft Threshold Function, IPSTF) tasarlanmış ve bu işlevle arıza sinyallerinin daha etkin bir şekilde korunması hedeflenmiştir. Ayrıca, Pseudo-Yumuşak Eşikleme Bloğu (Pseudo-Soft Threshold Block, PSTB) ve Uyarlanabilir Bir Eğim Bloğu (Adaptive Slope Block, ASB) ile eşik ve eğim değerleri adaptif olarak ayarlanarak Derin Artık Büzülme Ağı (Deep Residual Shrinkage Network, DRSN)'nin performansı artırılmıştır. İki farklı çalışma koşulunda gerçekleştirilen deneylerde, önerilen yöntem hem teşhis doğruluğu hem de kararlılık açısından mevcut yöntemlerden daha üstün performans göstermiştir. Özellikle düşük sinyal-gürültü oranlarında (SNR), IDRSN, geleneksel yöntemlerle kıyaslandığında %4.30-6.30 arasında daha yüksek bir doğruluk sunmuş ve standart sapmayı %40.63-53.67 oranında azaltmıştır. Değişken hız deneylerinde de benzer şekilde üstün performans sergilemiş, IDRSN'nin hata tipi teşhisinde %95'e kadar doğruluk sağlamıştır. Bu bulgular, IDRSN'nin gürültülü ortamlarda daha kararlı ve güvenilir bir teşhis yöntemi olduğunu ortaya koyduğunu göstermişlerdir (Tong ve ark., 2022).

Wang ve ark. (2023) yaptıkları çalışmada, değişken çalışma koşulları altında rulman arıza teşhisi için artımlı öğrenmeye dayalı bir çok görevli paylaşımlı sınıflandırıcı (Incremental Learning-Based Multi-Task Shared Classifier, IL-MTSC) yöntemini önermişlerdir. Rulmanların karmaşık ve zorlu çalışma ortamları nedeniyle arızalanma olasılığı yüksektir. Derin öğrenme tabanlı arıza teşhis yöntemleri yaygın olarak kullanılmakta ve tatmin edici performans sergilemektedir. Ancak, farklı koşullar altında toplanan test verileri kullanıldığında, önceki bilgilerin unutulmasına yol açan felaket unutma sorunu ortaya çıkmaktadır. Çalışmada önerilen IL-MTSC yöntemi, Bir Boyutlu Evrişimsel Sinir Ağı (One-Dimensional Convolutional Neural Network, 1D-CNN) modelini ana yapı olarak kullanmakta ve bilgi damıtma yöntemi ile modelin öğrendiği bilgileri korumasını sağlamışlardır. Ayrıca, farklı senaryolar altında çalışan bir paylaşımlı sınıflandırıcı oluşturularak, birleştirilmiş bir yapı kurmuşlardır. Çalışma, modelin değişken çalışma koşulları altında rulman arızalarını sürekli olarak öğrenebildiğini ve bu bilgileri koruyabildiğini göstermiştir. Üç farklı veri kümesinde yapılan deneyler, önerilen yöntemin teşhis doğruluklarının sırasıyla %98.27, %100.00 ve %100.00 olduğunu ortaya koymuştur. Bu sonuçlar, IL-MTSC'nin felaket unutma sorununu önemli ölçüde

hafiflettiğini ve diğer artımlı öğrenme yöntemlerine kıyasla üstün performans sergilediğini göstermişlerdir (Wang ve ark., 2023).

Bir diğer çalışmada Jin ve ark. (2023), trenlerin en kritik bileşenlerinden biri olan rulmanların durumunun güvenli operasyonla doğrudan ilişkili olduğu belirtmişlerdir. Rulmanların titreşim sinyalleri genellikle doğrusal olmayan ve durağansız karakterdedir, bu da arıza özelliklerinin çıkarılmasını zorlaştırmakta ve düşük teşhis doğruluğuna yol açmaktadır. Bu bağlamda, entropi teorisi, titreşim sinyalinin doğrusal olmayan ve karmaşıklık değişimini etkili bir şekilde ölçebilir. Ancak, geleneksel entropi algoritmaları çok kanallı sinyallerin özelliklerini aynı anda çıkaramaz. Bu sorunu aşmak için, bulanık mantık tabanlı Rafine Edilmiş Parçalı Bileşik Çok Değişkenli Çok Ölçekli Bulanık Entropi (Refined Piecewise Composite Multivariate Multiscale Fuzzy Entropy, RPCMMFE) ve CNN tabanlı bir rulman arıza teşhis yöntemini önermişlerdir. Önerilen yöntem, arıza özelliklerini tam olarak çıkarabilmekte ve teşhis doğruluğunu artırabilmektedir. İlk olarak, MMFE taban alınarak, rafine edilmiş teori ve parçalı bileşik teori kullanılarak RPCMMFE geliştirilmiştir. Daha sonra, farklı arıza sinyallerinin RPCMMFE'si hesaplanmış ve bu vektör, CNN'e giriş olarak kullanılarak arıza teşhisi yapılmıştır. İki farklı deney grubuyla doğrulanan bu yöntemin, daha iyi stabilite ve ayırt edicilik sağlayan özellikler çıkardığını ve rulman arızalarını daha yüksek doğrulukla tanımladığı göstermişlerdir. Deney sonuçlarında, yöntemin ortalama doğruluk oranları sırasıyla %99 ve %99.17 olarak rapor etmişlerdir (Jin ve ark., 2023).

Ye ve ark. (2023) yaptıkları çalışmada, rulman arıza teşhisi sırasında gürültü ortamlarında daha yüksek doğruluk sağlamak için, Varyasyonel Mod Çıkarımı (variational Mode Extraction, VME) ve Geliştirilmiş Tek Boyutlu Evrimsel Sinir Ağı (İmproved Onedimensional Convolutional Neural Network, I-1DCNN) tabanlı yeni bir akıllı arıza teşhis yöntemi önermişlerdir. VME, titreşim sinyallerindeki istenmeyen gürültüleri ortadan kaldırmak ve önemli mod bileşenlerini elde etmek için kullanılır. Elde edilen mod bileşenleri eğitim, doğrulama ve test setlerine ayrılır. Geliştirilmiş 1DCNN modeli, özellikle erken durdurma yöntemi ve kendinden dikkat mekanizması ile donatılmış olup, arıza özelliklerini daha etkin öğrenme ve aşırı öğrenme sorununu hafifletme kabiliyetine sahiptir. İki farklı deneysel veri seti üzerinde yapılan testlerde, önerilen yöntemin rulman arıza türlerini yüksek doğrulukla otomatik olarak tanıyabildiği ve gürültülü ortamda %95'in üzerinde tanıma doğruluğu sağladığı gösterilmiştir. Ayrıca, önerilen yöntem, diğer temsilci yöntemlerle kıyaslandığında daha üstün bir performans

sergileyerek rulman sađlık durumu izlemeye y6nelik g6c6l6 bir ara olduğunu kanıtlamışlardır (Ye ve ark., 2023).

Wu ve Zheng (2024) alıřmada, deđiřken y6k ve g6r6lt6 parazitlerinin etkisi altında geleneksel rulman arıza teřhis y6ntemlerinin yetersiz kaldıđı durumlara 6z6m getirmek amacıyla, ok 6lekli evriřimsel Sinir Ađı (Multi-Scale Convolutional Neural Network, MSCNN) ve Uzun Kısa S6reli Bellek (Long Short-Term Memory, LSTM) birleřimi bir model 6nermişlerdir. MSCNN, farklı boyutlardaki 6zellikleri adaptif bir řekilde ıkarmak iin ok 6lekli bir 6zellik ıkarma mod6l6 kullanır. Bu yapı, CNN'in g6c6l6 mekansal yerel 6zellik ıkarma kapasitesini kullanarak hem k66k hem de b6y6k evriřimsel ekirdekleri aracılıđıyla farklı boyutlardaki 6zellikleri 6đrenir. LSTM ise titreřim sinyalinin zamansal 6zelliklerini ıkarır ve b6ylece titreřim sinyallerindeki zaman dizisi bilgilerini dikkate alarak genel 6zelliklerin daha derinlemesine iřlenmesini sađlar. Son olarak, SoftMax sınıflandırıcı kullanılarak rulman arıza teřhisi gerekleřtirilir. alıřmada kullanılan Case Western Reserve University (CWRU) veri seti, rulmanların farklı sađlık kořullarındaki titreřim sinyallerini iermektedir ve bu veri seti, 6nerilen MSCNN-LSTM modelinin dođrulaması iin kullanılmıştır. Yapılan deneyler, modelin deđiřken y6k ve g6r6lt6 parazitleri altında y6ksek dođrulukla arıza tanısı yapabildiđini ve diđer y6ntemlerle karřılařtırıldığında daha iyi bir performans sergilediđini ortaya koymuřtur. 6rneđin, modelin deđiřken y6k kořullarında bile ortalama %98 dođruluk elde ettiđi ve rulman arızalarını bařarılı bir řekilde sınıflandırdıđı g6zlemlenmiştir. 6zellikle, modelin LSTM katmanlarıyla birleřik olması hem CNN hem de LSTM'nin g6c6l6 y6nlerini bir araya getirerek daha etkili 6zellik ıkarmasını m6mk6n kılmıştır. Deneysel sonular, CNN ile tek bařına yapılan modellere kıyasla, LSTM katmanlarının eklenmesiyle arıza tanıma performansının %3.5 oranında arttıđını g6stermiştir. Ayrıca, ok 6lekli Evriřimsel Yapı (MSCNN), paralel katmanlar aracılıđıyla ok eřitli arıza 6zelliklerini 6đrenerek, modelin genel performansını iyileřtirmiřtir. Bunun yanı sıra, modelde kullanılan Batch Normalization (BN) katmanları, modelin daha hızlı yakınsamasını sađlamış ve tanı dođruluđunu arttırmıştır. BN katmanının eklenmesiyle modelin %1 oranında daha y6ksek performans sergilediđi tespit edilmiştir. Sonu olarak, MSCNN-LSTM modeli, deđiřken alıřma kořullarında ve g6r6lt6 etkisi altında dahi y6ksek dođruluk ve genelleme kapasitesi sunarak rulman arıza teřhisinde 6nemli bir bařarı sađlamışlardır (Wu ve Zheng, 2024).

He ve ark. (2024) yaptıkları çalışma, değişken çalışma koşulları altında döner makinelerde yeni arıza türlerinin teşhis edilmesinde karşılaşılan katastrofik unutma sorununa çözüm sunmuşlardır. Geleneksel derin öğrenme modelleri yeni arıza türlerini öğrenirken unutma sorunu yaşamakta ve bu durum modellerin genelleme yeteneğini sınırlamaktadır. Bu problemi çözmek için araştırmacılar, gradyan artırma algoritmasından ilham alarak, yeni arıza türlerini adaptif bir şekilde öğrenebilen Özellik Artırmaya Dayalı Sürekli Öğrenme (Feature Boosting based Continual Learning, FBCL) yöntemini önermişlerdir. Bu yöntemde başlangıçta bir arıza teşhis modeli inşa edilmekte ve daha sonra modelin hata oranını düşürmek için yeni modüller dinamik olarak eklenmektedir. Logit fonksiyonu hizalaması ile sınıflandırma yanlılığı azaltılmakta, ayrıca dengeli bilgi damıtma stratejisi ile gereksiz parametreler çıkarılarak modelin tek omurga üzerinde sürekli öğrenmesi sağlanmaktadır. Deneysel sonuçlar, önerilen yöntemin mevcut karşılaştırmalı yöntemlerden daha iyi performans gösterdiğini ve %98 doğruluk oranıyla yeni arıza türlerini başarılı bir şekilde sınıflandırdığını ortaya koymuşlardır (He ve ark., 2024).

2.2. Rulman Ömrü Tespiti ile İlgili Literatür Çalışmaları

Liu ve Fan (2022) yaptıkları çalışmada, rulmanların kalan kullanım ömrünün (Remaining Useful Life, RUL) tahminine yönelik yeni bir stokastik süreç modeline dayalı bir yaklaşım önermişlerdir. Rulmanların bozulma süreci çok aşamalı ve değişken olduğundan, bu çalışmada çok aşamalı ve çok değişkenli bozulma trendlerini entegre eden yeni bir stokastik bozulma modeli geliştirmişlerdir. Aşama bölümü için ilk kez İstatistiksel Süreç Kontrolü (Statistical Process Control, SPC) kullanılmış ve aşamalar adaptif olarak değiştirilmiştir. Benzer rulmanlar hakkında ön bilgi bulunmadığında, Beklenti Maksimizasyonu (Expectation Maximization, EM) algoritması ile model parametreleri çevrimiçi olarak güncellenmiş ve farklı bozulma aşamalarında RUL tahmini gerçekleştirilmiştir. Çalışmanın etkinliği, simülasyon örneği ve XJTU-SY rulman veri seti ile yapılan deneysel çalışmalarla doğrulanmıştır. Sonuçlar, bu yaklaşımın rulman bozulma aşamalarını doğru şekilde bölebildiğini ve her aşamaya uygun RUL tahminleri sağlayabildiğini göstermektedir. Bu yöntem, özellikle çok aşamalı bozulma süreçlerinin tahmini için önemli bir katkı sunmaktadır. Gelecek çalışmalarda, içsel bozulma ve dışsal etkilerin etkileşimleriyle birlikte modelin genişletilmesi ve bozulma

sürecinde meydana gelen "sıçrama" veya "iyileşme" gibi durumların dikkate alınarak daha hassas RUL tahminlerinin yapılması önermişlerdir (Liu ve Fan, 2022).

Yan ve ark. (2020) yaptıkları çalışmada, döner makinelerde kritik bir bileşen olan rulmanların Kalan Kullanım Ömrünün (Remaining Useful Life, RUL) tahminine yönelik yenilikçi bir yöntem sunmuşlardır. Çalışmanın önemi, rulmanların bozulma aşamasını boyutsuz ölçümlerle değerlendirerek, hibrit bir bozulma izleme modeli kullanarak optimal RUL tahminini sağlamasıdır. İki yeni boyutsuz ölçüm, rulmanların titreşim şiddetini yansıtarak bireysel farklılıkları ortadan kaldırmakta, başlangıçtaki kusurlara karşı hassasiyeti artırmakta ve dalgalanmaları azaltmaktadır. Bu ölçümler, tahminin ne zaman başlayacağını tespit etmek ve boyutsuz bir arıza eşiği belirlemek için kullanılmaktadır. Destek vektör makineleri (Support Vector machine, SVM) sınıflandırıcısı, rulmanların bozulma aşamalarını değerlendirmek amacıyla kullanılmış ve yüksek sınıflandırma doğruluğu elde edilmiştir. SVM, genel bozulma modeline dayalı ölçümlerle eğitilmiş olup, beş farklı bozulma aşaması tanımlanmıştır. Ardından, hibrit bozulma izleme modeli kullanılarak rulmanların bozulma süreci takip edilerek optimal RUL tahmini gerçekleştirilmiştir. Önerilen yöntem, IMS ve PRONOSTIA rulman veri setleri ile doğrulanmış ve PRONOSTIA veri setindeki diğer yöntemlerle karşılaştırılmıştır. Sonuçlar, önerilen yöntemin %80 doğruluk oranına sahip olduğunu ve özellikle kademeli bozulma süreçlerinde başarılı bir performans gösterdiğini ortaya koymuşlardır (Yan ve ark., 2020).

Li ve ark. (2022) yaptıkları çalışmada, döner makinelerdeki rulmanların kalan kullanım ömrünün (Remaining Useful Life, RUL) tahmini için bir yöntem geliştirmişlerdir. RUL tahmininin doğruluğunu artırmak amacıyla risk değerlendirmesi ve bozulma durumu katsayısına dayalı bir yaklaşım önermişlerdir. Çalışmada, titreşim sinyallerinin zaman ve zaman-frekans alanındaki özelliklerine bağlı olarak Mahalanobis Mesafesi (Mahalanobis Distance, MD) hesaplanmıştır. Zaman-frekans alanındaki özellikler, Varyasyonel Mod Ayırıştırma-Tekil Değer Ayırıştırma (Variational Mode Decomposition-Singular Value Decomposition, VMD-SVD) yöntemini kullanarak çıkarmışlardır. MD1-CUMSUM (Mahalanobis Distance-Cumulative Sum) ile monoton olarak artan bir Sağlık Göstergesi (Health Indicator, HI) elde edilmiştir. Risk değerlendirmesi, ilk arıza ve başarısızlık eşiklerinin uyarlanabilir bir şekilde belirlenmesi amacıyla önerilmiştir. Test rulmanının RUL tahmini, Genetik Algoritma-Destek Vektör Regresyonu (Genetic Algorithm-Support Vector Regression, GA-SVR) ve bozulma durumu katsayısına sahip Modifiye Sağlık Göstergesi (Modified Health Indicator, MHI)

ile tamamlanmıştır. Önerilen yöntem, iki deneysel titreşim sinyali veri seti kullanılarak doğrulanmış ve rulmanların RUL tahmini konusunda yüksek bir doğruluk sergilediği göstermişlerdir (Li ve ark., 2022).

Bir diğer çalışmada Wang ve ark. (2021), rulmanların kalan kullanım ömrü tahmini için doğrusal bir güvenilirlik göstergesi yaklaşımını önermişlerdir. RUL tahmininin doğruluğunu artırmak amacıyla, birden fazla Derin Otomatik Kodlayıcı (Deep Auto-Encoder, DAE) modeli kullanılarak derin özellikler çıkarılmış ve kümeleme tabanlı bir yöntemle orijinal özellik seti seçmişlerdir. Orijinal özellik setinden en uygun özellikler, monotonluk ve korelasyon indeksi (Mon ve Corr) kullanılarak belirlenmiş ve bu özelliklerle doğrusal bir güvenilirlik göstergesi oluşturmuşlardır. Bu doğrusal güvenilirlik göstergesi, orijinal özellik setini dönüştürerek bir haritalama özellik setine dönüştürmektedir. Son aşamada, bu haritalama özellik seti bir güvenilirlik değerlendirme modeli ile eğitilmiş ve Parçacık Filtresi (Particle Filter) sezgisel algoritma kullanılarak RUL tahminini yapmışlardır. Yöntemin etkinliği, PRONOSTIA rulman veri setleri kullanılarak doğrulanmıştır. Deneysel sonuçlar, önerilen yöntemin, kademeli olarak bozulan rulmanlar için yüksek doğrulukta RUL tahmini sağlayabildiğini göstermişlerdir. Ayrıca, bu çalışma, entegre model ve kümeleme yöntemleri ile özelliklerin genelleme ve sağlamlığını artırmış, doğrusal haritalama tekniği ise özelliklerin korelasyon ve monotonluğunu iyileştirerek dalgalanmalarını azaltmıştır. Ancak, bu yaklaşımın ani arızaları değerlendirmedeki yetersizliği bir sınırlama olarak belirtmişlerdir. Gelecekte, ani arızaların mekanizmaları üzerine araştırmalar yapmayı planlamaktadırlar (Wang ve ark., 2021).

Du ve ark. (2022) yaptıkları çalışmada, döner makinelerin kritik bir bileşeni olan rulmanların kalan kullanım ömrünün (RUL) tahmini için dikkat mekanizmasına dayalı çok ölçekli konvolüsyonel sinir ağı (Multi-Scale Convolutional Neural Network, MSCNN) tabanlı bir model önermişlerdir. Rulmanların bozulma eğilimlerini tahmin etmek ve RUL'lerini belirlemek, makinelerin bakımını planlamak ve beklenmeyen arızaları önlemek açısından büyük öneme sahiptir. Önerilen modelde, birinci adımda sensörle toplanan bir boyutlu titreşim sinyalleri, Sürekli Dalga Dönüşümü (Continuous Wavelet Transform, CWT) kullanılarak iki boyutlu zaman-frekans spektrum haritalarına dönüştürülmüştür. İkinci adımda, rulmanların sağlık indekslerini belirlemek için kuadratik bozulma fonksiyonu kullanılmıştır. Üçüncü adımda ise, MSCNN modeli ile derin özellik çıkarımı gerçekleştirilmiş ve farklı boyutlardaki evrimsel çekirdekleri aracılığıyla sinyalin bozulma özellikleri çıkarılmıştır. Modelin doğruluğunu artırmak için

Evrişimsel Blok Dikkat Modülü (Convolutional Block Attention Module, CBAM) eklenmiş ve gürültüye karşı dayanıklılığı artırmak için Üstel Doğrusal Birim (Exponential Linear Unit, ELU) aktivasyon fonksiyonu uygulanmıştır. Çalışma, PRONOSTIA veri seti kullanılarak test edilmiş ve diğer yöntemlerle karşılaştırıldığında daha düşük tahmin hatası ve daha yüksek doğruluk oranı elde edilmiştir. Sonuçlar, önerilen modelin tahmin doğruluğunu ve genelleme kapasitesini artırarak, rulmanların RUL tahmininde üstün bir performans sergilediğini ortaya koymuştur. Diğer derin öğrenme yaklaşımlarıyla yapılan karşılaştırmada, önerilen CBAM-MSCNN modelinin daha yüksek doğruluk sunduğu ve tahmin hatasını en aza indirdiği görülmüştür. Önerilen yöntemin başarı yüzdesi hakkında tam sayısal bir veri sağlanmamış olsa da, önceki modellere kıyasla üstün sonuçlar verdiği belirtilmiştir (Du ve ark., 2022).

Lee ve ark. (2022) yaptıkları çalışmada, rulmanların kalan kullanım ömrünü (RUL) tahmin etmek amacıyla sistematik özellik mühendisliği ve Aşırı Öğrenme Makinesi (extreme learning machine, ELM) modeline dayanan yenilikçi bir yöntem önermişlerdir. Özellikle rafineri ve kimya tesislerinde kullanılan pompalar ve kompresörler gibi döner makinelerde, rulmanların kritik öneme sahip bileşenler olmasından ve bu bileşenlerde meydana gelen arızaların ekonomik kayıplara veya güvenlik sorunlarına yol açabilmesinden kaynaklanmaktadır. Bu nedenle, rulmanların RUL tahmini, üretim kayıplarını azaltmak ve makine hasarını önlemek için büyük bir rol oynamaktadır. Ancak, rulman arıza mekanizmalarının karmaşık ve stokastik doğası, veri odaklı RUL tahmin yöntemlerinin önemini artırmaktadır. Önerilen yöntem, dört adımdan oluşmaktadır. İlk olarak, rulman sağlığı ile yakından ilişkili ve farklı rulmanlar arasında karşılaştırılabilir bir sağlık göstergesi (Health Indicator, HI) oluşturulmaktadır. Bu adımda, standartlaştırma yaklaşımı ve Hareketli Ortalama (Moving Average, MA) filtreleme kullanılarak rulmanlar arası ve rulman içi değişkenlik azaltılmaktadır. İkinci adımda, oluşturulan HI trendi kullanılarak rulmanın normal çalışıp çalışmadığı veya bozulmaya başlayıp başlamadığı belirlenmektedir. Üçüncü adımda, sistematik özellik mühendisliği kullanılarak, fiziksel anlamı olan ve makine öğrenimi modelleri için tahmin gücü yüksek özellikler oluşturulmaktadır. Son adımda ise, eğitim rulmanlarının oluşturulan özellikleri kullanılarak ELM modelleri eğitilmekte ve test rulmanlarının RUL tahmini yapılmaktadır. Önerilen yöntemin performansı PRONOSTIA veri seti kullanılarak test edilmiştir ve Derin Sinir Ağı (Deep Neural Network, DNN) ile Derin Sinir Ağı ve Çok Ölçekli Bulanık Entropi (Deep Neural Network - Multiscale Fuzzy Entropy, DNN-MSFE) tabanlı diğer iki yöntemle karşılaştırılmıştır. Elde edilen sonuçlar,

önerilen yöntemin tüm rulmanlar için tüm performans metriklerinde üstün bir performans gösterdiğini ortaya koymuştur (Lee ve ark., 2022).

Bir diğer çalışmada Cheng ve ark. (2021), rulmanların kalan kullanım ömrünün tahminine odaklanmakta olup, özellikle birden fazla arıza modunun neden olduğu farklı arıza davranışları altında tutarsız öznitelik dağılımlarının tahmin modeli performansını olumsuz etkilediği durumlardaki zorlukları ele almışlardır. Bu sorunu çözmek amacıyla, önerilen çalışmada Transfer Evrişimsel Sinir Ağı (Transferable Convolutional Neural Network, TCNN) kullanılarak farklı arıza davranışları altında RUL (Remaining Useful Life, RUL) tahmininde yüksek doğruluk elde edilmeye çalışılmıştır. Yöntemde, ilk olarak, bir Evrişimsel Sinir Ağı (CNN) kullanılarak bozulma öznitelikleri çıkarılmaktadır. Ardından, Birden Fazla Çekirdek Maksimum Ortalama Farklılık (Multiple-Kernel Maximum Mean Discrepancies, MK-MMD) optimizasyon terimiyle entegre edilerek, farklı arıza davranışları arasındaki dağılım uyumsuzluğu azaltılmaktadır. Bu sayede, eğitilmiş TCNN modeli, rulman verilerini kullanarak RUL tahmininde kullanılabilir hale gelmektedir. Çalışmanın etkinliği, bir arızaya kadar çalışma veri seti üzerinde doğrulanmış olup, elde edilen sonuçlar, önerilen yöntemin çekirdek seçiminin etkilerini önleyerek alan adaptasyonu performansını önemli ölçüde iyileştirdiğini ve daha iyi bir RUL tahmin performansı sağladığını göstermektedir. Özellikle, önerilen TCNN yöntemi, geleneksel yöntemler ve diğer transfer öğrenme yöntemleri Aktarılabilir Çok Katmanlı Algılayıcı (Transferable Multiple Layer Perceptron, TMLP) ve Sinir Ağlarının Alan-Çekişmeli Eğitimi (Domain-adversarial training of neural networks, DANN) ile karşılaştırıldığında daha yüksek doğruluk sağlamıştır. Çalışmada kullanılan veri seti ve elde edilen sonuçlar, bu yöntemin rulman RUL tahmininde önemli bir adım olarak değerlendirilebileceğini göstermişlerdir (Cheng ve ark., 2021).

Liu ve ark. (2021) yaptıkları çalışmada, RUL tahmini için veri odaklı yaklaşımların artan önemini vurgulamışlardır. Rulmanlar, makinelerin temel bileşenleri olarak işlev görmekte olup, durumları ekipmanın normal işleyişiyle yakından ilişkilidir. Bu nedenle, rulmanların RUL'unu doğru bir şekilde tahmin etmek kritik öneme sahiptir. Çalışmada, rulmanların bozulma süreci incelenmiş ve gelişmiş bir kodlayıcı-kod çözücü yöntemi önermişlerdir. Bu yöntem, kodlayıcının geriye dönük bilgi toplama yeteneğine sahip bir kod çözücü oluşturmayı hedeflemektedir. Ek olarak, sağlık göstergelerinin kalitesini artırmak amacıyla trigonometrik fonksiyonlar ve kümülatif işlemler kullanılmıştır. Önerilen yöntemin etkinliğini doğrulamak için PRONOSTIA

platformundan elde edilen titreşim verileri kullanılmıştır. Deneysel sonuçlar, bu yöntemin mevcut yöntemlerle karşılaştırıldığında ortalama mutlak hata (MAE) değerinde %31.41'lik bir iyileşme sağlamıştır. Ayrıca, performans metriği olarak kullanılan "score" değeri %4.23, "score $\times$ 100/MAE" değeri ise %51.95 oranında arttırmışlardır. Çalışmada, kodlayıcı-kod çözücü yapısı ve dikkat mekanizması kullanılarak, titreşim verilerinden elde edilen özellikler kümülatif formlara dönüştürülmüş ve modelin performansı çeşitli güncel yöntemlerle karşılaştırılmıştır. Sonuçlar, geliştirilen modelin uygulanabilirliğini açıkça göstermişlerdir (Liu ve ark., 2021).

Wang ve ark. (2019) yaptıkları çalışmada, RUL tahmininde derin öğrenme tekniklerinin güçlü temsil öğrenme yeteneğinden yararlanılarak yeni bir derin öngörü ağı olan Derin Ayrılabilir Evrişimsel Ağı (Deep Separable Convolutional Network, DSCN) önermişlerdir. Derin öğrenme tabanlı bu yöntemler, makine bozulma bilgilerini daha verimli bir şekilde çıkarmayı başarsa da, el yapımı özellik tasarımı olan bağımlılıkları ve farklı sensör verilerinin ilişkilerini açıkça dikkate almamaları gibi zayıf yönleri sahiptirler. Bu zayıflıkları gidermek amacıyla geliştirilen DSCN, farklı sensörler tarafından toplanan izleme verilerini doğrudan öngörü ağına girdisi olarak kullanır. DSCN'nin temelinde, ayrılabilir evrişimler ve sıkıştırma-uyarma (squeeze and excitation) işlemleri ile oluşturulmuş ayrılabilir evrişimsel yapı bloğu bulunmaktadır. Bu yapı bloğu, çok katmanlı olarak istifleterek, girdi verilerinden yüksek seviyeli temsiller otomatik olarak öğrenilir ve nihayetinde RUL tahmini bu temsillerin tam bağlantılı çıkış katmanına beslenmesiyle gerçekleştirilir. Önerilen DSCN, yuvarlanan eleman rulmanlarının hızlandırılmış bozulma testlerinden elde edilen titreşim verileri ve kamuya açık türbin motorları bozulma simülasyon verileri kullanılarak doğrulanmışlardır. Deneysel sonuçlar, DSCN'nin hem çoklu sensör verilerine dayalı olarak doğru RUL tahmin sonuçları sağlayabildiğini hem de mevcut bazı veri tabanlı öngörü yaklaşımlardan üstün olduğunu göstermişlerdir (Wang ve ark., 2019).

Bir diğer çalışmada Pan ve ark. (2020), döner elemanlı rulmanların aniden arızalanarak mekanik ekipmanlara zarar vermesini önlemek amacıyla, rulmanların durumunu izlemek ve RUL'u hızlı ve doğru bir şekilde tahmin etmek için iki aşamalı bir tahmin yöntemi önermişlerdir. Önerilen yöntem, rulmanların çalışma aşamasını ikiye ayırmak için Göreceli Kök Ortalama Kare (Relative Root Mean Square Value, RRMS) değerini kullanır: normal operasyon ve bozulma aşamaları. İlk olarak, rulmanların normal operasyon aşamasında, tek değişkenli tahmin ilkesi doğrultusunda, rulman bozulma eğilimini kısa vadeli olarak gerçek zamanlı tahmin etmek amacıyla Geri Beslemeli Bir

Aşırı Öğrenme Makinesi (Feedback Extreme Learning Machine, FELM) modeli oluşturmuşlardır. Tahmin edilen değer, rulmanın bozulma aşamasına girdiğini gösterdiğinde, hassas özellikler korelasyon analizi ile seçilerek, çok değişkenli regresyon ve küçük örnek tahmin avantajlarını bir araya getiren Çok Değişkenli Geri Beslemeli Aşırı Öğrenme Makinesi (Multivariate feedback extreme learning machine, MFELM) modeli oluşturulur. Deneysel sonuçlar, önerilen yöntemin, sınırlı öğrenme örnek boyutu durumunda daha yüksek kısa vadeli tahmin doğruluğu ve daha hızlı çalışma hızı sağladığını göstermektedir. Özellikle, MFELM modelinin zaman alanındaki göreceli karakteristik değişkenler arasındaki korelasyonları tam olarak dikkate aldığı ve küçük örnek verilerindeki potansiyel bilgileri maksimize ettiği vurgulanmıştır (Pan ve ark., 2020).

Ahmad ve ark. (2019) yaptıkları çalışmada, yuvarlanmalı eleman rulmanlarının RUL tahmini ve yaklaşan arızaların öngörülmesi için güvenilir bir teknik önermişlerdir. Rulman arızaları, endüksiyon motorlarında en sık karşılaşılan arıza türüdür ve bu arızalar, üretim tesislerinde beklenmedik ve uzun süreli duruşlara neden olarak büyük ekonomik kayıplara yol açabilir. Bu nedenle, rulmanların sağlığının tahmini ve RUL'unun doğru bir şekilde belirlenmesi, ani duruşların önlenmesi ve bakım planlaması için kritik öneme sahiptir. Çalışmada önerilen yöntem, rulmanın sağlığını boyutsuz bir sağlık göstergesi (Health Indicator, HI) aracılığıyla değerlendirir ve dinamik regresyon modelleri kullanarak RUL'u tahmin eder. HI, rulmanın anlık titreşim seviyesini normal bir referans değere göre ölçer. Regresyon modelleri, rulmanın sağlık göstergesindeki değişen trendi yakalamak için tekrarlamalı olarak güncellenir ve bu modeller gelecekteki sağlık göstergesi değerlerini proje etmek ve rulmanın RUL'unu tahmin etmek için kullanılır. RUL tahmini, yeni bir yaklaşımla Tahmin Başlangıç Zamanı (Time To Start Prediction, TSP) belirlendikten sonra gerçekleştirilir. Önerilen algoritma, PRONOSTIA veri setinde test edilip doğrulanmış ve genişletilmiş Kalman filtresi ile parçacık filtreleriyle geliştirilmiş bir üstel model gibi iki ileri düzey teknikle karşılaştırılmıştır. Deney sonuçları, önerilen yöntemin uygun bir TSP belirleme yeteneği ve rulman sağlık göstergesindeki trende uyum sağlamak için dinamik olarak kalibre edilen regresyon modelleri sayesinde üstün bir performans sergilediğini göstermişlerdir (Ahmad ve ark., 2019).

Li ve ark. (2019) yaptıkları çalışmada, modern endüstrilerde makine bozulmasının doğru bir şekilde değerlendirilmesi amacıyla derin öğrenme tabanlı yenilikçi bir RUL tahmin yöntemi önermişlerdir. Fiziksel modellerin karmaşık sistemleri tanımlama

kapasitesinin sınırlı kalmasıyla, veri odaklı yaklaşımlar ön plana çıkmıştır. Çalışma, zaman-frekans domain bilgilerini kullanarak kestirim yapılması ve çok ölçekli özellik çıkarımının Evrimsel Sinir Ağları (Convolutional Neural Network, CNN) ile uygulanmasını önermektedir. Önerilen yöntem, PRONOSTIA platformundan elde edilen rulman veri seti üzerinde test edilmiş ve diğer yöntemlerle karşılaştırıldığında üstünlüğünü kanıtlamışlardır. Deney sonuçları, yöntemin yüksek doğrulukta RUL tahmini sağladığını ve endüstriyel uygulamalar için umut verici olduğunu göstermişlerdir. Bu çalışmada kullanılan veri seti PRONOSTIA platformundan alınmış olup, çok ölçekli özellik çıkarımı ve zaman-frekans domain bilgileri kullanılarak, derin öğrenme yönteminin üstünlüğü ortaya koymuşlardır (Li ve ark., 2019).

Hu ve ark. (2022) yaptıkları çalışmada, farklı çalışma koşulları altında kalan kullanım ömrü (Remaining Useful Life, RUL) tahminini zorlaştıran veri dağılım farklarını gidermek amacıyla, derin özellik ayrıştırma ve transfer öğrenme tabanlı yeni bir yöntem olan Derin Özellik Ayrıştırma Transfer Öğrenme Ağı (Deep Feature Disentanglement Transfer Learning Network, DFDTLN) önermişlerdir. Geleneksel transfer öğrenme yöntemleri, genel çapraz alan özelliklerinin dağılım farklılıklarını minimize etmeye odaklanırken, her alanın kendine özgü özelliklerini göz ardı eder. Bu durum, bir alanın özel temsilcilerinin diğer alanlardaki RUL tahminine olumsuz etki etmesine yol açar. DFDTLN, alanlar arası paylaşılan ortak temsiller ve özel temsillerin iki eklemlili otomatik kodlayıcı (autoencoder) kullanılarak ayrıştırılmasını sağlar. Önerilen yöntem, IEEE PHM Challenge 2012 rulman veri seti üzerinde test edilmiştir ve diğer derin öğrenme (Deep Learning, DL) ve Transfer Öğrenme (Transfer Learning, TL) tabanlı yöntemlerle karşılaştırıldığında, daha alan-bağımsız ve RUL tahmini için uygun özellikler çıkardığını göstermiştir. Sonuçlar, DFDTLN'nin derin özellikleri ayrıştırarak alan spesifik özelliklerin olumsuz etkilerini zayıflattığını ve böylece daha başarılı tahmin sonuçları elde ettiğini ortaya koymaktadır. Çalışmada kullanılan veri seti IEEE PHM Challenge 2012 rulman veri setidir. Yöntemin başarımlı yüzdesi hakkında spesifik bir değeri belirtilmemiştir, ancak diğer yöntemlerle karşılaştırıldığında üstünlük sağladığı vurgulanmıştır (Hu ve ark., 2022).

Wang ve ark. (2022) yaptıkları çalışmada, dönen makinelerin kalan kullanım ömrü (RUL) tahminini iyileştirmek amacıyla adaptif Durum Değişim Hızı (State Change Rate, SCR) belirleme algoritması ile birlikte Tahminsel Kaydırılmalı Yerel Aykırı Değer Düzeltmesi (Predictive Sliding Local Outlier Correction, PSLOC) yöntemini önermişlerdir. Mevcut rulman sağlamlık tahmin yöntemlerindeki bazı temel sorunları ele alan

bu yöntem, özellikle zaman serisi verilerindeki rastgele ve anormal dalgalanmaları ortadan kaldırarak, bozulma sürecinin bütünlüğünü korur ve RUL tahmininin doğruluğunu artırır. PSLOC yöntemi, anormal dalgalanmaları tespit edip düzelterek, bozulma eğrisinin stabilitesini ve monotonluğunu iyileştirir ve bu sayede İlk Tahmin Zamanının (First Predicting Time, FPT) belirlenmesinde daha hassas sonuçlar elde edilmesini sağlar. Ayrıca, SCR algoritması, bozulma sürecindeki değişikliklere göre FPT'yi aktif olarak ayarlayarak daha doğru tahminler yapılmasına imkan tanır. Önerilen yöntem, PRONOSTIA veri seti üzerinde test edilmiş ve özellikle rulman bozulma verileri için üstün performans sergilemişlerdir. Sonuçlar, PSLOC yönteminin, FPT belirleme ve RUL tahmininde önemli iyileşmeler sağladığını göstermişlerdir (Wang ve ark., 2022).

Bir diğer çalışmada Chen ve ark. (2020), döner makinelerdeki rulmanların kalan kullanım ömrü (RUL) tahmini için tamamen veri odaklı ve minimum ön bilgi gerektiren bir yöntem önermişlerdir. RUL tahmini, durum bazlı bakım sistemlerinin oluşturulmasında kritik bir konudur. Ancak, mevcut veri odaklı yaklaşımlar, büyük veri çağında verimsiz olan önceden belirlenmiş özelliklerin çıkarılmasını, sağlık göstergesinin (Health Indicate, HI) oluşturulmasını ve eşiklerin belirlenmesini gerektirir. Bu çalışmada önerilen yöntem üç aşamadan oluşmaktadır: özellik çıkarma, HI tahmini ve RUL hesaplama. İlk aşamada, frekans spektrumunun beş bant geçiş enerji değeri özellik olarak çıkarılır. Daha sonra, kodlayıcı-kod çözücü çerçevesine dayanan ve dikkat mekanizması ile güçlendirilmiş bir tekrarlayan sinir ağı kullanılarak HI değerleri tahmin edilir. Bu HI değerleri, doğrudan RUL değerleri ile ilişkilendirilmiştir. Son olarak, lineer regresyon ile nihai RUL değeri hesaplanır. PRONOSTIA veri seti üzerinde yapılan deneyler ve diğer yaklaşımlarla yapılan karşılaştırmalar, önerilen yöntemin daha iyi performans gösterdiğini ortaya koymuşlardır (Chen ve ark., 2020).

Yoo ve ark. (2018) yaptıkları çalışmada, kalan kullanım ömrü (RUL) tahmini için yeni bir yaklaşım önermişlerdir. Geleneksel yöntemler, sağlık göstergesi (Health Indicator, HI) oluşturmak için zaman, frekans ve zaman-frekans analizleri kullanarak sensör verilerinden birçok özellik çıkarılmasını ve bunların birleştirilmesini gerektirmektedir. Bu çalışmada, bir boyutlu titreşim sinyallerini iki boyutlu (Two-Dimensional, 2-D) görüntülere dönüştürmek için Sürekli Dalgacık Dönüşümü (Continuous Wavelet Transform, CWT) kullanılarak zaman-frekans görüntü özellikleri elde edilmiştir. Elde edilen görüntü özellikleri, HI oluşturmak için iki boyutlu evrimsel sinir ağına (convolutional neural network, CNN) beslenmiştir. CNN tabanlı modelden tahmin edilen HI, RUL tahmini için kullanılmıştır. PRONOSTIA tarafından sağlanan

rulman veri seti kullanılarak doğrulanan bu yöntem, karmaşık özellik çıkarımı, seçimi ve birleştirme süreçlerini tek bir algorithmada birleştirdiği için büyük bir avantaj sağlamaktadır. Sonuçlar, önerilen yöntemin mevcut çalışmalara göre daha yüksek doğrulukta RUL tahmini sağladığını göstermişlerdir (Yoo ve ark., 2018).

Rathore ve ark. (2022) yaptıkları çalışmada, yüksek hızlı rulmanların kalan kullanım ömrünü (RUL) doğru bir şekilde tahmin etmek için veri odaklı bir yöntem önermişlerdir. Geleneksel fiziksel tabanlı modeller ve istatistiksel yöntemlere kıyasla, veri odaklı yöntemlerin yaygın kullanımı artmıştır. Bu çalışma, rulmanların bozulma süreci ile mevcut sağlık durumu arasındaki temel ilişkiyi belirlemek amacıyla 'Dikkat Mekanizmasına Sahip İki Yönlü Yığılmış Uzun Kısa Süreli Bellek Ağı (Stacked Bi-directional Long Short Term Memory, SBiLSTM) çerçevesini önermektedir. İki yönlü LSTM, geçmiş ve gelecek durumları aynı anda işleyebilme yeteneğine sahip olduğundan, zaman serisi verilerinden yararlı bozulma bilgilerini çıkarabilir. Çalışmada, PRONOSTIA platformundan elde edilen veri seti üzerinde deneysel validasyon yapılmış ve önerilen yöntemin performansı, kök ortalama kare hatası (Root Mean Square Error , RMSE) ve ortalama mutlak hata (Mean Absolute Error, MAE) kriterlerine göre diğer güncel yöntemlerle karşılaştırıldığında üstünlük göstermiştir. Deneysel sonuçlar, dikkat mekanizması ve uygunluk analizi ile desteklenen A-SBiLSTM yönteminin, rulman RUL tahmini için diğer gelişmiş yöntemlere göre daha başarılı olduğunu ortaya koymuştur. Önerilen yöntem, ham titreşim verilerinden elde edilen çoklu özellikleri kullanarak uygunluk analizi ile en uygun tahmin özelliklerini seçmekte ve bu özellikleri kullanarak rulman bozulma sürecini etkili bir şekilde modellemektedir. Deneysel çalışmalar, hızlandırılmış yaşam testi kullanılarak yüksek hızlı rotor destekli test düzeneklerinde gerçekleştirilmiş ve elde edilen sonuçlar, önerilen yöntemin genel performansının oldukça tatmin edici olduğunu göstermiştir. (Rathore ve ark., 2022).

Cui ve ark. (2024) yaptıkları çalışmada, mühendislik uygulamalarında rulmanların kalan kullanım ömrü tahmini için yetersiz yaşam döngüsü verisi sorununun üstesinden gelmek amacıyla dijital ikiz destekli grafik alan uyarlama yöntemi önermişlerdir. İlk olarak, rulmanların tam yaşam döngüsünü simüle eden dinamik bir dijital ikiz modeli oluşturulmuş ve yüzey morfolojisinin evrimi ve farklı aşamalarındaki rulman bileşenlerinin kayma hareketleri analiz edilerek titreşim verileri üretilmiştir. İkinci olarak, geleneksel alan uyarlama yöntemlerinin Öklid dışı verileri işleme yetersizliğini çözmek için Çok Katmanlı Çapraz Alanlı Kapılı Grafik Evrişim Ağı (Multi-Layered Cross-Domain Gated Graph Convolutional Network, MGGCN) geliştirilmiştir.

Bu ağ, uzamsal ve zamansal özellikleri, doğrusal olmayan dönüşümler ve önceki zaman adımı gizli durumu entegrasyonu ile çıkarmaktadır. Ayrıca, grafik özellik dağılımlarını uyumlu hale getirmek için Grafik Laplasyen Düzenlenmiş Maksimum Ortalama Tutarsızlık (Graph Laplacian Regularized Maximum Mean Discrepancy, GLMMD) adı verilen yeni bir düzenleyici kayıp fonksiyonu tasarlanmış ve modelin eğitimi sırasında kullanılmıştır. PRONOSTIA veri seti ile yapılan deneyler, önerilen yöntemin sınırlı veri ile bile etkili bir performans sergilediğini ve gerçek veri kalitesine bağımlılığı azalttığını göstermişlerdir (Cui ve ark., 2024).

Kumar ve ark. (2024) yaptıkları çalışmada, döner elemanlı rulmanların kalan kullanım ömrü tahmini için yeni bir yaklaşım sunmuşlardır. Geleneksel RUL tahmin modelleri, sensörler aracılığıyla toplanan sinyallerin istatistiksel özelliklerine dayanmakta ve genellikle tek tip çalışma koşullarında etkili olmaktadır. Ancak, gerçek dünyada makineler farklı çalışma koşullarına maruz kaldığından, bu modellerin farklı koşullar altında aynı başarıyı gösteremediği görülmektedir. Bu sorunu çözmek amacıyla, bu çalışmada titreşim verilerinin 16 bant geçiren filtreli frekans bileşenlerinden elde edilen teğetsel entropi özelliklerine İzometrik Haritalama (Isometric Mapping, ISOMAP) uygulanarak bir sağlık göstergesi geliştirmişlerdir. Bu sağlık göstergesi, rulmanın bozulma eğilimlerini izlemekte ve veri odaklı RUL tahmin modelinin geliştirilmesi için kullanılmaktadır. Modelin farklı çalışma koşulları altında etkin bir şekilde çalışabilmesi için özellik tabanlı ve anlık tabanlı alan uyarlama teknikleri uygulanmıştır. Sonuçlar, bu alan uyarlama tekniklerinin uygulanmasıyla modelin, tüm çalışma koşullarındaki verilere dayanan modellerle benzer bir performans sergileyebildiğini göstermişlerdir (kumar ve ark., 2024).

Sun ve Wang (2024) yaptıkları çalışmada, rulmanların kalan kullanım ömrü tahmini için yeni bir yöntem önermişlerdir. Geleneksel veri madenciliği ve bozulma özelliklerinin çıkarılması yöntemlerindeki sınırlamaları aşmak amacıyla, yazarlar Simetrik Nokta Deseni (Symmetrized Dot Pattern, SDP) ve Bileşik Çok Ölçekli Permütasyon Entropisi (Composite Multiscale Permutation Entropy, CMPE) yöntemlerini birleştirmiştir. SDP-CMPE yöntemi, sensör verilerini detaylı bir şekilde işleyerek büyük miktardaki veriyi görüntülere dönüştürür ve önemli bilgilerin kaybını engeller. Bu yöntemle çıkarılan bozulma özellikleri, zaman alanındaki beş yaygın özellik ile karşılaştırılmış ve beş değerlendirme kriteri (monotonluk, sağlamlık, korelasyon, öngörülebilirlik ve eğilim) açısından üstün performans göstermiştir. Ayrıca, Elman sinir ağı kullanılarak RUL tahmini yapılmış ve SDP-CMPE yönteminin yüksek tahmin

doğruluđu ve düşük ađ karmaşıklığı ile rulmanların bozulma süreçlerinin daha etkin şekilde tahmin edilmesini sağladığı kanıtlamışlardır. Deneyler, bu yöntemin rulmanların RUL tahmininde önemli bir avantaj sağladığını ve ekipmanların bakımını iyileştirerek hizmet ömrünü uzatmada pratik bir anlam taşıdığını göstermişlerdir (Sun ve Wang 2024).



3. MATERYAL VE YÖNTEM

3.1. Materyal

3.1.1. Rulman arıza tespiti için kullanılan veri setleri

Rulman verileri, özel olarak tasarlanmış bir rulman-mili montajından elde edilmiştir. Bu deneysel kurulumda ana bileşenler, bir AC servo motor, Düşük Voltaj Direktifi (Low Voltage Directive, LVD) sürücü, iki ekseninde yer alan titreşim sensörleri, radial ve eksenel yönlerde sabit basınç sağlamak için iki valf, bir sinyal kondüktörü ve Şekil 3.1'de gösterilen Ulusal Enstrümanlar Veri Toplama (National Instruments Data Acquisition, NIDAQ 6211) kartıdır. Veri toplamak için Ulusal Enstrümanlar 6211 veri toplama kartı (DAQ) kullanılmıştır. Titreşim sinyallerini elektrik sinyallerine dönüştürmek için piezo-elektrik malzemeden yapılmış bir titreşim sensörü (352C65) kullanılmıştır. Sensörlerden gelen titreşim sinyallerini kontrol etmek ve yükseltmek için sinyal kondüktörleri (PCB 484B06) kullanılmıştır. Rulmanda hata boyutunu sınıflandırmak için belirli çaplarda yapay hatalar oluşturulmuştur. Rulmanda yapay hatalar dışında ekstra bir titreşimin olmaması için yapay hataların özenle açılması gerekmektedir. Bunun için lazer delme yöntemi ile mikron hassasiyetinde iç bilezik, dış bilezik ve bilya üzerine 0,15 mm 0,5 mm ve 0,9 mm çapında delikler açılmıştır (Kaplan ve ark., 2015; Bayram ve ark., 2014).



Şekil 3. 1. Titreşim verisi toplama şeması

Test düzeneğinde ilk etapta hatasız bir rulmandan elde edilen veriler kaydedilmiştir. Sonrasında rulmanların iç bilezik, dış bilezik ve bilyalarında gerçekleştirilen yapay hatalardan (mm) alınan veriler kaydedilmiştir. Veri toplama aşamasında belirlenen 5 farklı hız için testler tekrarlanmıştır. Böylelikle rulmanlardan farklı hız, farklı hata boyutu (mm) ve farklı hata türleri iç bilezik hatası (Inner Race), dış bilezik hatası (Outer Race) ve bilya boyutu (Ball Size) için veriler elde edilmiştir.

Tablo 3. 1. Veri seti1 farklı hızlar için oluşturulan veri kümesi

Veri seti1	Yapay Arıza Türü (Hız)			
Deney Numarası	IR (mm)	OR (mm)	BS (mm)	Hız (rpm)
1	0.9	0.9	0	1500
2	0.9	0.9	0	1740
3	0.9	0.9	0	1800
4	0.9	0.9	0	1860
5	0.9	0.9	0	2100


Tablo 3. 2. Veri seti2 rulman arıza tipleri için oluşturulan veri seti

Veri seti2	Yapay Arıza Türü (Tip)			
Deney Numarası	IR (mm)	OR (mm)	BS (mm)	Hız (rpm)
1	0.00	0.00	0.00	1800
2	0.9	0.0	0.0	1800
3	0.0	0.9	0.0	1800
4	0.0	0.0	0.9	1800

Tablo 3. 3. Veri seti3 OR için rulman hata boyutları veri seti


Veri seti3	Yapay Arıza Türü (Boyut)			
Deney Numarası	IR (mm)	OR (mm)	BS (mm)	Hız (rpm)
1	0.00	0.00	0.00	1800
2	0.00	0.15	0.00	1800
3	0.00	0.5	0.00	1800
4	0.00	0.9	0.00	1800

Bu çalışmada 3 farklı veri seti kullanılmıştır. Tablo 3.1.'de birinci veri setine ait farklı Dakikadaki Devir Sayısı (Revolutions Per Minute, RPM)'lerde elde edilen işaretler bulunmaktadır. Tablo 3.2.'de farklı rulman hata türlerine ait veri seti bulunmaktadır. Tablo 3.3.'te ise farklı boyutlarda dış bilezik hatası bulunan rulmandan elde edilen veri seti verilmiştir. 1500, 1740, 1800, 1860 ve 2100 RPM'lerden oluşan işaretlere ait örnek titreşim işaretleri Şekil 3.2.'de verilmiştir.




Şekil 3. 2. Farklı rpm'lerde elde edilen örnek işaretler. (A) 1500 rpm, (B) 1740 rpm, (C) 1800 rpm, (D) 1860 rpm, (E) 2100 rpm.

İkinci veri setinde 1800 RPM'de alınan ancak farklı hatalara ait işaretler bulunmaktadır. Hatasız, iç bilezik, dış bilezik ve bilye üzerinde hata durumunda ölçülen işaretler içermektedir. Bu hata durumlarına ait örnek işaretler Şekil 3.3.'te verilmiştir.



Şekil 3. 3. Farklı hata türlerine ait işaretler. (A) iç bilezik hatalı, (B) dış bilezik hatalı, (C) bilezik hatalı, (D) hatasız işaretler

Son veri setinde 1800 RPM’de alınan hata boyutları değişen örnek işaretler bulunmaktadır. Hatalar dış bilezikte 0.15 mm, 0.5mm, 0.9 mm ve 0 mm olan titreşim işaretlerinden oluşmaktadır. Bu hatalı işaretlere ait örnekler Şekil 3.4.’te verilmiştir.



Şekil 3. 4. Farklı boyutlardaki hatalara ait örnek işaretler. (A) 0.15 mm hatalı, (B) 0.9 mm hatalı, (C) 0.5 mm hatalı, (D) hatasız işaretler


Diğer bir çalışmada 2 farklı veri seti kullanılmıştır. Tablo 3.4.’de farklı rulman hata türlerine ait veri seti bulunmaktadır. Tablo 3.5.’de ise farklı boyutlarda dış bilezik hatası bulunan rulmandan elde edilen veri seti ile ilgili bilgiler verilmiştir. Birinci veri setinde 2100 RPM’de alınan ancak farklı hatalara ait işaretler bulunmaktadır. Hatasız, iç bilezik, dış bilezik ve bilye üzerinde hata durumunda ölçülen işaretler içermektedir. İkinci veri setinde 2100 RPM’de alınan hata boyutları değişen örnek işaretler bulunmaktadır. Hatalar dış bilezikte 0.15 mm, 0.5mm, 0.9 mm ve 0 mm olan titreşim işaretlerinden oluşmaktadır. İki veri seti örnek titreşim sinyalleri Şekil 3.5. ve Şekil 3.6.’de verilmiştir.

Tablo 3. 4. Veri seti1 rulman arıza tipleri için oluşturulan veri seti


Veri seti1	Yapay Arıza Türü (Tip)			
Deney Numarası	IR (mm)	OR (mm)	BS (mm)	Hız (rpm)
1	0.00	0.00	0.00	2100
2	0.15	0.0	0.0	2100
3	0.0	0.15	0.0	2100
4	0.0	0.0	0.15	2100

Tablo 3. 5. Veri seti2 BS için rulman arıza boyutlarına ilişkin veri seti

Veri seti2	Yapay Arıza Türü (Boyut)			
Deney Numarası	IR (mm)	OR (mm)	BS (mm)	Hız (rpm)
1	0.00	0.00	0.00	2100
2	0.00	0.00	0.15	2100
3	0.00	0.00	0.5	2100
4	0.00	0.00	0.9	2100



Şekil 3. 5. Farklı arıza tiplerinin sinyalleri. (A) arızasız, (B) iç halka arızası, (C) dış halka arızası (D) küresel arıza




Şekil 3. 6. Farklı arıza boyutlarının örnek sinyalleri (A) 0,15 mm arıza, (B) 0,9 mm arıza, (C) 0,5 mm arıza (D) arızasız sinyaller

3.1.2. Rulman ömrü tahmini için kullanılan veri seti

PRONOSTIA veri seti, FEMTO ST Enstitüsü, Besançon, Fransa tarafından geliştirilen Pronostia isimli Şekil 1’de gösterilen deneysel platformundan sağlanmıştır. Bu veri seti, üç farklı hızlandırılmış bozulma koşuluna tabi tutulan 17 setten oluşmaktadır (Yan ve ark., 2020). Şekilde gösterilen PRONOSTIA platformu üç ana parçaya sahiptir. Bir AC motor, bir dişli kutusu veya hız düşürücü ve iki şafttan oluşan dönen bir parça; dönen rulmanlar radyal olarak yüklemek ve dolayısıyla bozulmalarını hızlandırmak için bir pnömatik basınç regülatörü ve bir kuvvet aktarma mekanizmasından oluşan bir yükleme parçası; ve anlık çalışma koşullarını belirlemek için sensörlerden, yani kuvvet sensörü, hız sensörü ve tork ölçerden ve rulman bozulmasını karakterize etmek için sensörlerden, yani titreşim sensörleri veya ivmeölçerler ve bir termokupldan oluşan bir ölçüm parçası. Çalışma koşullarını belirlemek için kullanılan üç ölçüm 100 Hz. frekansta yapılmıştır. PRONOSTIA platformunda, rulman bozulmasının karakterizasyonu için titreşim ve sıcaklık ölçümleri gibi iki tür ölçüm elde edilebilir. Ancak bu çalışmada, rulmanların aşınmasını karakterize etmek ve RUL değerlerini tahmin etmek için sadece titreşim ölçümlerini kullanılmıştır. Bu veriler bilyeli rulmanların bozuluncaya kadar elde

edilen titreşim işaretlerinden oluşmaktadır. Deneylerde, yatakların aşınmasını hızlandırmak için radyal bir yük kuvveti uygulanmıştır. X ve Y yönlerindeki titreşim sinyalleri 25600 Hz. örnekleme frekansı ile elde edilmiştir. 10'ar saniyelik kayıtlar alınmıştır. Gerçekleştirilen deneyler Tablo 1'de verilmiştir (Du ve ark., 2022; Ahmad ve ark., 2019)



Şekil 3. 7. Pronostia platformu (Nectoux ve ark., 2012)

Tablo 3. 6. Pronostia platformundan elde edilen veri setleri

	Çalışma Koşulları		
	Koşul 1	Koşul 2	Koşul 3
Yük (N)	4000	4200	5000
Hız (rpm)	1800	1650	1500
Rulmanlar/Tüm ömür	Bearing1_1 Bearing1_2 Bearing1_3 Bearing1_4 Bearing1_5 Bearing1_6 Bearing1_7	Bearing2_1 Bearing2_2 Bearing2_3 Bearing2_4 Bearing2_5 Bearing2_6 Bearing2_7	Bearing3_1 Bearing3_2 Bearing3_3


Tablo 3.6.'da verilen bilgilere göre 3 farklı hızda ve yükte denemeler gerçekleştirilmiştir. İlk çalıştırma koşulları 1800 rpm ve 4000 N, İkinci çalıştırma

koşulları 1650 rpm ve 4200 N Üçüncü çalıştırma koşulları 500 rpm ve 5000 N. Bu çalışmada gerçekleştirilen rulman ömrü tahmin senaryoları Tablo 3.7’de verilmiştir.

Tablo 3. 7. Deneysel senaryolar


Senaryo	Eğitim Seti	Test Seti
Senaryo 1	Bearing1_1, Bearing1_2	Bearing 1_3
Senaryo 2	Bearing1_1, Bearing1_2	Bearing 1_4
Senaryo 3	Bearing1_1, Bearing1_2	Bearing 1_5
Senaryo 4	Bearing1_1, Bearing1_2	Bearing 1_6
Senaryo 5	Bearing1_1, Bearing1_2	Bearing 1_7
Senaryo 6	Bearing2_1, Bearing2_2	Bearing 2_3
Senaryo 7	Bearing2_1, Bearing2_2	Bearing 2_4
Senaryo 8	Bearing2_1, Bearing2_2	Bearing 2_5
Senaryo 9	Bearing2_1, Bearing2_2	Bearing 2_6
Senaryo 10	Bearing2_1, Bearing2_2	Bearing 2_7
Senaryo 11	Bearing3_1, Bearing3_2	Bearing 3_3

Bearing 1_1’a ait titreşim işaretleri Şekil 3.8.(A)’da ve bu titreşim işaretlerin zaman içindeki değişimini belirten Root Mean Square(RMS) değerleri Şekil 3.8.(B)’de verilmiştir.



Şekil 3. 8. Bearing1_1 için (A) örnek titreşim sinyalleri, (B) titreşim sinyallerine ait rms değerleri

Zaman içinde bu titreşim işaretlerin düzensizleştiği görülmektedir. Zamanla rulmanda meydana gelen bozulmalardan dolayı titreşim işaretlerinde dalgalanmalar artmaktadır. Bearing1_3 ve Bearing1_4 için dalgalanmalar Şekil 3.9.'da gösterilmiştir.




Şekil 3. 9. Titreşim sinyallerindeki rms değerleri ve sinyallerdeki dalgalanmalar

Rulmanların çalışma koşullarından dolayı çalışma süreleri (Ömürleri) değişkenlik göstermektedir. Bu yüzden bu ömürleri tahmin edecek bir model ortaya koymak zorlaşmaktadır. İncelenen literatürlerde rulman ömrü etiketi olarak farklı yaklaşımların olduğu görülmektedir. Bu çalışmada bir rulman çalışma süreleri sinyal uzunluğunun yarısından sonra aşağıdaki denklem 3.1 ve denklem 3.2 ile hesaplanmıştır (Cao ve ark., 2021). Bu işlem rulman normalleştirme etiketi olarak ifade edilmektedir.

$$RUL_t = Total\ Life - t \quad (3.1)$$

$$RUL_{t-norm} = \frac{RUL_t}{Total\ Life} \quad (3.2)$$

Burada *Total Life* bir rulmanın çalışma süresini belirtir. RUL_{t-norm} Değeri 0-1 arasında normalleşmiş olur. Örneğin Bearing_1_1 ve Bearing_1_2 için ömür eğrileri Şekil 3.10.'daki gibi olmaktadır.



Şekil 3. 10. Rulman ömür gösterimleri

3.2. Metot

3.2.1. Aşırı makine öğrenmesi ile entropi varyantlarını kullanarak rulman arıza teşhisi

3.2.1.1. Özellik çıkarım yöntemleri

Makine öğrenimi modellerinin işlevselliği, büyük ölçüde etkin özellik çıkarma yöntemlerinin kullanımına bağlıdır. Veri setini karakterize eden özellikler, makine öğreniminin verimli çalışmasına katkıda bulunacaktır. Doğrusal olmayan teorinin gelişmesiyle birlikte, entropi tabanlı özellik çıkarma yöntemleri de geliştirilmiştir. Çünkü entropi bilgisi, arıza özelliklerini etkili bir şekilde temsil edebilir. Bu entropi algoritmaları, sinyallerin karmaşıklığını tek bir adımda ölçtüğü için, genellikle zaman serileri ve tek boyutlu sinyallerle gerçekleştirilen mekanik teşhis araştırmalarında tercih edilen yöntemler arasında yer almaktadır (Kaya ve ark., 2022).

- **Yaklaşık Entropi (ApEn)**

Yaklaşık entropi hem deterministik kaotik hem de stokastik süreçleri içeren çeşitli formlardaki karmaşık sistemleri sınıflandırılabilme için önerilmiş güçlü bir belirteçtir. Limitli verilerdeki karmaşıklığı ayırt etmede kullanılabilir. Yaklaşık entropi, bir zaman serisindeki dalgalanmaların öngörülemezliğini ölçen bir düzenlilik istatistiğidir. Nispeten daha yüksek bir yaklaşık entropi değeri, benzer gözlem örüntülerinin ardından ek benzer gözlemlerin gelme olasılığının yüksek olduğu anlamı taşımaktadır. Yaklaşık entropi fonksiyonu ilk başta, gömülü boyut m ve gecikme τ ile N veri noktası için gecikmeli bir yeniden yapılandırma $Y_{1:N}$ üretir. Bu metot ile daha sonra, i noktasında verilen hedef noktaların sayısı denklem 3.3 ile hesaplanır:

$$N_i = \sum_{j=1, j \neq i}^N 1(\|Y_i - Y_j\|_\infty < R) \quad (3.3)$$

burada 1, indikatör fonksiyonu ve R , benzerlik yarıçapıdır. Yaklaşık entropi daha sonra şu denklem 3.4 ve denklem 3.5 kullanılarak hesaplanabilir (Pincus, 1991).

$$ApEn = \Phi_m - \Phi_{m+1} \quad (3.4)$$

$$\Phi_m = (N - m + 1)^{-1} \sum_{i=1}^{N-m+1} \log(N_i) \quad (3.5)$$

• Örnek Entropi (SampEn)

Örnek entropi de yaklaşık entropi gibi de bir karmaşıklık ölçütüdür ve yaklaşık entropinin düzenlenmiş halidir. Kendine benzer örüntüleri yaklaşık entropide olduğu gibi içermez. Aynı zamanda verisetinin uzunluğu bu metodun başarımlar oranını etkilemez. Yaklaşık entropide, sinyalin kod şablonunun kendisine eşit kabul edildiği kendi kendine eşleşmeden dolayı bir bias (öteleme) vardır. Belirli bir m gömülü boyutlu, r toleranslı N veri noktası için, *SampEn*, m uzunluğundaki veri dizisi " $< r$ " mesafesine sahipse, $m + 1$ uzunluğundaki veri dizisinin de " $< r$ " mesafesine sahip olma olasılığının negatif doğal logaritmasıdır. SampEn fonksiyonunu tanımlamak için, sabit τ zaman aralığına sahip $N = \{x_1, x_2, x_3, \dots, x_N\}$ boyutlu bir zaman serisini ele alabiliriz. m uzunluğundaki bir şablon vektör $X_m(i) = \{x_i, x_{i+1}, x_{i+2}, \dots, x_{i+m-1}\}$ ve bu vektörün uzaklık matrisi Chebyshev mesafesi (ancak Öklid uzaklığı da dahil olmak üzere herhangi bir uzaklık fonksiyonu seçilebilir) olacak şekilde $d[X_m(i), X_m(j)]$ ($i \neq j$) olsun.

$$B = \left\{ \frac{[(N-m-1)(N-m)]}{2} \right\} B^m(r) \quad (3.6)$$

ve

$$A = \left\{ \frac{[(N-m-1)(N-m)]}{2} \right\} A^m(r) \quad (3.7)$$

Denklem 3.6'da B $d[X_{m+1}(i), X_{m+1}(j)] < r$ sahip şablon vektör çiftlerinin sayısını, $A^m(r)$, r toleransında $m+1$ noktası sayısı ile eşleşen iki veri dizisinin olasılığını göstermektedir. Denklem 3.7'de ise A $[X_m(i), X_m(j)] < r$ sahip şablon vektör çiftlerinin sayısını, $B^m(r)$ ise r toleransında bir m sayısı noktası için eşleşen iki veri dizisinin olasılığını temsil etmektedir. Her iki parametrede de kendi kendine eşleşmelerden kaçınılmıştır. Denklem 3.6 ve Denklem 3.7 kullanılarak örnek entropi Denklem 3.8 ile hesaplanabilir (Richman ve Moorman, 2000).

$$SampEn = -\ln \frac{A}{B} \quad (3.8)$$

- **Bulanık Entropi (FuzzyEn)**

Örnek entropi tanımında (Richman ve Moorman, 2000), derece vektör benzerliği Heaviside fonksiyonu ile tanımlanır:

$$\theta(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3.9)$$

Heaviside fonksiyonu girişleri iki gruba ayırmaktadır. Sınıflama sonucu oluşan grupların sınırları genellikle belirsizdir; bu nedenle, girdi örneği her zaman tek bir sınıfa güvenle yerleştirilemez. Bu sorunu çözmek için SampleEn'deki Heaviside fonksiyonu yerine, vektörlerin benzerlik derecesini ölçmek için bulanık üyelik fonksiyonu kullanılmıştır. FuzzyEn özniteliğini bulmak için aşağıda gerekli olan prosedür sırası ile verilmiştir. N-noktalı örnek bir zaman serisi $\{u(i): 1 \leq i \leq N\}$ dizisi ele alalım. Dizi sırasına göre $u(i)$ üzerinde faz-uzay rekonstrüksiyonu uygulanır ve bir dizi m -boyutlu vektör elde edilir ($m \leq N - 2$). Yeniden yapılandırılmış vektörü daha sonra Denklem 3.10'daki gibi elde edilir.

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i) \quad (3.10)$$

Burada $i = 1, 2, \dots, N - m + 1$, ve $u_0(i)$ ortalama değerdir. $u_0(i)$ Denklem 3.11 ile bulunabilir.

$$u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j) \quad (3.11)$$

O halde, d_{ij}^m yani X_i^m ve X_j^m vektörleri arasındaki uzaklık Denklem 3.12 ile tanımlanabilir.

$$d_{ij}^m = d[x_i^m, x_j^m] = \max_{k \in (0, m-1)} \{|u(i+k) - u_0(i) - u(j+k) - u_0(j)|\} \quad (3.12)$$

Burada $(i, j = 1, \dots, N - m, j \neq i)$ dir.

Bulanık üyelik fonksiyonu $\mu(d_{ij}^m, n, r)$, X_i^m ve X_j^m vektörleri arasındaki D_{ij}^m benzerlik derecesi Denklem 3.13'deki gibi tanımlanabilir.

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = \exp\left(\frac{-(d_{ij}^m)^n}{r}\right) \quad (3.13)$$

Burada bulanık üyelik fonksiyonu expnsiyonel fonksiyondur, n ve r sırasıyla üstel fonksiyonun gradyanı ve genişliğidir. Daha sonra $\phi(n, r)$ tanımlanırsa Denklem 3.14 elde edilir.

$$\phi(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left[\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m \right] \quad (3.14)$$

Denklem (3.10)'dan (3.14)'e kadar olan adımları aynı şekilde tekrarlırsak, bir dizi ($m + 1$) boyutlu vektör dizi sırasına göre yeniden Denklem 3.15'teki gibi oluşturulabilir.

$$\phi^+(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left[\frac{1}{N-m-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^{m+1} \right] \quad (3.15)$$

Artık belirli bir zaman serisi için bulanık entropiyi Denklem 3.16'daki gibi tanımlayabiliriz.

$$FuzzyEn(m, n, r) = \lim_{N \rightarrow \infty} [\ln \phi^m(n, r) - \phi^{m+1}(n, r)] \quad (3.16)$$

N sınırlı olduğunda, dizi uzunluğu N olan zaman serileri için bulanık entropi Denklem 3.17 ile ifade edilebilir.

$$FuzzyEn(m, n, r) = \ln \phi^m(n, r) - \phi^{m+1}(n, r) \quad (3.17)$$

burada m ve r , sırasıyla faz uzayı ve benzerlik toleransının boyutlarıdır. Genel olarak, çok büyük bir benzerlik toleransı ile yararlı bilgiler kaybolabilir. Bununla birlikte, benzerlik toleransı önemsenmez ise, gürültüye karşı hassasiyet önemli ölçüde artacaktır (Xiang ve ark., 2015; Xie ve ark., 2008).

- **Kolmogorov Entropisi (K2En)**

Kolmogorov entropi (K2En), zaman boyunca kaotik yörüngelerden elde edilen bilginin oranını tanımlar. K2En büyümesi ile sistem daha fazla bilgi kaybeder ve sistem daha kaotik hale gelir. K2En entropisi Grassberger ve Procaccia tarafından geliştirilen 2. dereceden Kolmogorov entropisine temsil etmektedir (Grassberger ve Procaccia,1983).

L örnekleme noktasına sahip bir zaman serisi $\{X_i\}_{i=1}^L$ gömülü boyut m ve gecikme zamanı τ , faz uzayı $\left(\{X_i\}_{i=1}^{L-(m-1)\tau}\right)$ yeniden oluşturmak için seçilir ve denklem 3.18'deki zaman serisi oluşturulur.

$$X_i = [X_i, X_{i+\tau}, X_{i+2\tau}, \dots, X_{i+(m-1)\tau}] \quad (3.18)$$

Faz uzayı tekil spektrum analizi kullanılarak ortogonal faz uzayına dönüştürülür. Korelasyon integrali denklem 3.19'daki gibi elde edilebilir.

$$C_m^2(r_1) = \frac{1}{N^2} \sum_{i,j=1}^N (r_1 - \theta |x_i - x_j|) \quad (3.19)$$

Burada θ Heaviside fonksiyonunu temsil etmektedir. r_1 , 0'dan büyük ise $\theta(r_1)$ 1'e eşit, değilse $\theta(r_1)$ 0'a eşittir. Ölçeksiz aralıkta, K2En öznelilik dizisi denklem 3.20 kullanılarak elde edilebilir (Liang ve ark., 2015; Gao ve ark., 2013).

$$K2EN = \frac{1}{\tau} \ln \left[\frac{C_m^2(r_1)}{C_{m+1}^2(r_1)} \right], \quad r_1 \rightarrow \infty, m \rightarrow \infty \quad (3.20)$$

- **Kenar Permütasyon Entropisi (PermEn)**

PermEn, Bandit ve Pompe tarafından, zaman serilerinin karmaşıklığının ve düzensizliğinin tahminini gerçekleştirmek için geliştirilmiştir (Bandt ve Pompe2002). Bu tahmin ile zaman serilerini sembolik dizilere eşlenerek sıra örüntülerinin olasılık dağılımına dayalı olarak gerçekleştirilmiştir. PermEn kısaca şu şekilde hesaplanabilir. Bir zaman serisi $\{x_i, i = 1, 2, \dots, N\}$ N noktalı m gömülü boyutlu ve τ gecikme zamanı ile verilirse Denklem 3.21'deki gibi $N - (m - 1)\tau$ gömülü vektör elde edilebilir.

$$X_m(i) = \{x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(m-1)\tau}\} \quad (3.21)$$

Daha sonra her $X_m(i)$ m gerçek değerleri artan sıraya göre denklem 3.22 gibi düzenlenebilir.

$$x_{i+(j_1-1)\tau} \leq x_{i+(j_2-1)\tau} \leq \dots \leq x_{i+(j_m-1)\tau} \quad (3.22)$$

Her elde edilen $X_m(i)$ gömülü vektörleri sembolik dizilere denklem 3.23 kullanılarak eşlenir.

$$\pi_n = (j_1, j_2, \dots, j_m) \quad (3.23)$$

Burada π_n m farklı sembole sahip $m!$ sembol permütasyonlarından biridir. $\{P(\pi_1), P(\pi_2), \dots, P(\pi_k), n = 1, 2, \dots, k \text{ and } k = m!\}$, $\sum_{n=1}^k P(\pi_n) = 1$ tabi olarak sırasıyla her derece permütasyonunun olasılık dağılımını gösterir. Her π_n permütasyonu için göreceli olasılık dağılımı denklem 3.24 ile hesaplanabilir.

$$P(\pi_n) = \frac{\#\{X_m(i) \text{ depend on type } \pi_n\}}{N-(m-1)\tau} \quad (3.24)$$

Daha sonra, sonlu bir zaman serisi için, PermEn denklem 3.25'teki gibi tanımlanabilir.

$$P(m, \tau) = -\sum_{n=1}^{m!} P(\pi_n) \log_2(P(\pi_n)) \quad (3.25)$$

PermEn $[0, \log_2 m!]$ arasında değişen değerler almaktadır. PermEn minimum değeri, zaman serisinin büyük olasılıkla periyodik bir sinyal olduğunu gösterir. PermEn değerinin büyümesi ile, zaman serisindeki düzensizlik artar. Bu nedenle, PermEn zaman serilerinde yerel düzen yapısını tanımlamak için elverişlidir (Huo ve ark., 2019).

- **Dağılım Entropisi (DispEn)**

Dağılım entropisi (DispEn) zaman serilerinin düzenliliğini ölçmek için kullanılmış bir entropi çeşitidir. Zaman serilerini çok iyi karakterize eden eşleme

yeteneğine sahiptir. Tek değişkenli N uzunluğunda bir zaman serisi $x = \{x_1, x_2, x_3, \dots, x_N\}$ Dispersion entropisi şu şekilde hesaplanabilir:

- (i) İlk olarak, $\{x_j, j = 1, 2, \dots, N\}$ c sınıflara 1'den c ye kadar indislenerek eşlenir. Sınıflandırılmış sinyaller $\{z_j, j = 1, 2, \dots, N\}$ ile temsil edilir. Normal kümülatif dağılım fonksiyonu (NCDF), x değerini, 0 ile 1 arasında değişen $y = \{y_1, y_2, \dots, y_n\}$ kümesine eşlemek için kullanılır. Daha sonra, doğrusal bir algoritma ile her bir y_j , 1'den c 'ye kadar bir tam sayı değerine atanır. Bunun için, sinyalin her bir üyesi $z_j^c = \text{round}(c \cdot y_j + 0.5)$ (burada z_j^c sınıflandırılmış j th zaman serisi üyesini gösterir.) denklemi kullanılmıştır.
- (ii) Her gömülü vektör $z_i^{m,c}$, m gömülü uzunluk ve gecikme zamanı τ kullanılarak $z_i^{m,c} = \{z_i^c, z_{i+\tau}^c, \dots, z_{i+(m-1)\tau}^c\}, i = 1, 2, \dots, N - (m-1)\tau$ göre oluşturulmuştur. Her $z_i^{m,c}$, bir $\pi_{v_0 v_1 \dots v_{m-1}}$ (ki burada $z_i^c = v_0, z_{i+\tau}^c = v_1, \dots, z_{i+(m-1)\tau}^c = v_{m-1}$) dağılım örüntüsüne eşleştirilmiştir. Her zaman serisine atanabilecek dağılım örüntülerin sayısı $z_i^{m,c}$, sinyalin m tane üyesinin olması ve her üyenin 1'den c ye kadar olan tamsayılardan biri olması nedeniyle c^m sayısına eşittir.
- (iii) Her c^m potansiyel bir dağılım örüntüsüdür ve göreceli frekans denklem 3.26'a göre hesaplanabilir.

$$p(\pi_{v_0 v_1 \dots v_{m-1}}) = \frac{\text{Number}\{i | i \leq N - (m-1)\tau, z_i^{m,c} \text{ has type } \pi_{v_0 v_1 \dots v_{m-1}}\}}{N - (m-1)\tau} \quad (3.26)$$

$p(\pi_{v_0 v_1 \dots v_{m-1}})$ burada dağılım örüntülerinin sayısını gösterir. $\pi_{v_0 v_1 \dots v_{m-1}}$ dağılım örüntüsü $z_i^{m,c}$ 'ye toplam gömülü sinyallerin m gömülü boyutuna bölünmesi ile atanmıştır.

- (iv) Sonuçta Shannon entropi tanımı ile DispEn entropisi denklem 3.27'deki gibi elde edilmiştir (Rostaghi ve Azami, 2016).

$$\text{DispEn}(x, m, c, \tau) = - \sum_{\pi=1}^{c^m} p(\pi_{v_0 v_1 \dots v_{m-1}}) \cdot \ln(p(\pi_{v_0 v_1 \dots v_{m-1}})) \quad (3.27)$$

- **Koşullu Entropi (CondEn)**

Zaman serişlerinde düzenliliği ölçen bir başka yöntem ise koşullu entropi(CondEn) yaklaşımıdır. Durağansızlıktan yararlanarak, $\{X(i), i = 1, 2, \dots, N, \text{with } i \text{ temporal index}\}$ dizisi denklem 3.28 kullanılarak normalizasyon yoluyla sıfır ortalamalı ve üniter varyanslı bir sürece indirgenir.

$$x(i) = \frac{x(i) - av[X]}{std[X]} \quad (3.28)$$

Burada $av[X]$ ve $std[X]$ sırasıyla dizinin ortalama ve standart sapmayı göstermektedir. Normalleştirilmiş seriden, yeniden oluşturulmuş L boyutlu faz uzayı 1'e eşit gecikme ile birlikte $N - L + 1$ boyutlu $x_L(i) = (x(i), x(i-1), \dots, x(i-L+1))$ vektörleri elde edilir. Her $x_L(i)$ vektörü L ardışık örnekli örüntüleri temsil etmektedir.

CondEn denklem 3.29 ile şekilde hesaplanabilir.

$$\text{CondEn} \left(\frac{L}{L-1} \right) = - \sum_{L-1} p_{L-1} \sum_{L/L-1} p_{L/L-1} \log p_{L/L-1} \quad (3.29)$$

Burada p_{L-1} , $x_{L-1}(i)$ örüntüsünün ortak olasılığını, $p_{L/L-1}$ parametresi ise bir önceki $L-1$ örneğinde verilen $x_L(i)$ örüntüsünün L 'inci örneğinin koşullu olasılığını sembolize eder. İlk toplam tüm farklı $x_{L-1}(i)$ örüntülerine genişletilirken, ikincisi $x_L(i)$ örüntüsün tüm farklı L 'inci örneklerine genişletilir. Daha sonra CondEn $x_L(i)$ 'nin Shannon Entropi (SE) tanımını yardımı ile bulunabilir.

$$\text{CondEn} (L) = - \sum_L p_L \log p_L \quad (3.30)$$

Burada p_L , $x_L(i)$ örüntüsünün ortak (joint) olasılığını gösterir ve toplam farklı $x_L(i)$ örüntülerine genişletilebilir. Aslında CondEn SE'nin L 'ye göre değişimi olarak elde edilebilir.

$$\text{CondEn} (L/L-1) = \text{CondEn} (L) - \text{CondEn} (L-1) \quad (3.31)$$

Burada $\text{CondEn} (1/0) = \text{CondEn} (1)$ olarak varsayılır (Porta ve ark., 1998).

- **Güç Spektrumu Entropisi (SpecEn)**

Tek boyutlu sinyallerin düzensizliğini ölçerek, orantılılık dağılımının düzgünlüğü hakkında bilgi edinilebilir. Güç spektral entropisi kavramı (SpecEn), frekans bileşenlerinin dağılımına bağlı olan frekans alanındaki Shannon entropisinin uzantısıdır. Belirli bir sinyalin güç spektral entropisi aşağıdaki adımlar izlenilerek elde edilebilir.

(i) Bir $x(t)$ sinyalinin SpecEn değeri denklem 3.32 ile bulunabilir.

$$s(f) = \frac{1}{2\pi N} |X(w)|^2 \quad (3.32)$$

Burada N parametresi $x(t)$ sinyalinin uzunluğunu göstermektedir. $X(w)$ değeri ise $x(t)$ sinyalinin Hızlı Fourier Dönüşümü (FFT) ile elde edilmiş Fourier dönüşümüdür.

(ii) Spektrum için olasılık yoğunluk fonksiyonu böylece tüm frekans bileşenleri üzerinden normalizasyon yoluyla denklem 3.33 kullanılarak tahmin edilebilir.

$$p_i = s(f_i) / \sum_{k=1}^N s(f_k), \quad i = 1, 2, \dots, N \quad (3.33)$$

Burada sırasıyla, $s(f_i)$ f_i 'nin frekans bileşeninin spektral enerjisini, p_i bu frekanslara karşılık gelen olasılık yoğunluğunu, N ise FFT dönüşümündeki toplam frekans bileşen sayısını göstermektedir.

(iii) Karşılık gelen güç spektral entropisi H denklem 3.34 ile elde edilebilir.

$$H = - \sum_{k=1}^N p_i \log p_i \quad (3.34)$$

Farklı çalışma koşullarında da kullanılabilir ve karşılaştırılabilir olması için, elde edilen sonuç $\log N$ faktörü ile denklem 3.35'teki gibi normalizasyon edilir.

$$SpecEn = \frac{H}{\log N} = \frac{- \sum_{k=1}^N p_i \log p_i}{\log N} \quad (3.35)$$

Güç spektral entropisi $SpecEn$ $[0, 1]$ aralığında boyutsuz bir göstergedir. $SpecEn$ değerinde 1 frekans bileşeni dağılımı nispeten eşit ve belirsiz olan spektruma karşılık

gelirken, 0 değeri ise dağılımın belirsizliğinin en az olduğu spektruma karşılık gelir (Inouye ve ark., 1991).

- **Dağılım Entropisi (DistEn)**

Distribution Entropy (DistEn) tek boyutlu sinyallerinin karmaşıklığını ölçmede etkin olarak kullanılmak için geliştirilmiştir. Önceden belirlenmiş parametrelere bağlı olmaması ve veri uzunluğu ile sınırlı olmayan bir yöntemdir. DistEn, olasılık yoğunluğu tahmini ile durum uzayındaki vektörden vektöre mesafelerin altında yatan kalıtsal bilgileri kullanarak sağlam bir karmaşıklık analizi gerçekleştirmektedir. DistEn entropisi N noktalı $\{u(i), 1 \leq i \leq N\}$ dizisi için aşağıdaki algoritma ile bulunabilir (Li ve ark., 2015).

- (i) m gömülü boyutlu $(N - m)$ adet $X(i)$ vektörleri durum uzayında rekonstrüksiyon yapılır. $X(i)$ vektörleri $X(i) = \{u(i), u(i + 1), \dots, u(i + m - 1)\}, 1 \leq i \leq N - m$ olarak oluşturulur.
- (ii) $D = \{d_{i,j}\}$ uzaklık matrisi $X(i)$ ve $X(j)$ vektörleri arasından tüm $1 \leq i, j \leq N - m$ için tanımlanır. Burada $X(i)$ ve $X(j)$ vektörleri arasındaki $d_{i,j} = \max\{|u(i + k) - u(j + k)|, 0 \leq k \leq m - 1\}$ Chebyshev uzaklığı kullanılır.
- (iii) Olasılık yoğunluğu tahmini $1 \leq i, j \leq N - m$ için tüm $d_{i,j}$ 'nin dağılım özellikleri, uzaklık matrisi D 'nin temel bilgilerin tam nicelleştirilmesi olmalıdır. Burada D 'nin ampirik olasılık yoğunluk fonksiyonunu (ePDF) tahmin etmek için histogram yaklaşımını uygulanır. Histogramın M kutusu varsa, her bölmenin olasılığını (sıklığını) belirtmek için $p_t = 1, 2, \dots, M$ kullanılır. Önyargıyı azaltmak için, ePDF tahmin edilirken $i = j$ öğeleri hariç tutulur.
- (iv) $u(i)$ dizisinin DistEn değeri Shannon entropisinin klasik formülü olan denklem 3.36 kullanılarak elde edilir.

$$DistEn(m, M) = - \sum_{t=1}^M p_t \log_2(p_t) \quad (3.36)$$

- **Sembolik Dinamik Entropi (SyDyEn)**

Symbolic Dynamic Entropy (SyDyEn) yöntemi bir dizinin ölçek üzerinden dinamik özelliklerini değerlendirerek zaman serilerinin düzenliliğini ölçer. Verilen bir $X\{x(k), k = 1, 2, \dots, N\}$ dizisinin SyDyEn yöntemi 4 adımda hesaplanabilir.

(i) Zaman serisini sembol zaman serisine dönüştürün (sembolleştirme). Zaman serisinin genlik alanı, benzersiz ε hücrelerine bölünmüştür. Ardından, eleman biri $\sigma_i (i = 1, 2, \dots, \varepsilon)$ sembolüne dönüştürülerek, sembol zaman serisi $Z\{z(k), k = 1, 2, \dots, N\}$ elde edilir. Örneğin, $x(k)$ vektörünün genliği ε hücresine aitse, $z(k)$ ögesi ε sembolüne karşılık gelir. Daha sonra genlik olanı bölütlendirme için maksimum entropi bölümlendirme (maximum entropy partitioning, MEP) kullanılır.

(ii) Sembol zaman serisine dayalı olarak gömülü vektörler oluşturulur ve potansiyel durum örüntülerinin olasılığı hesaplanır. Gömülü vektörler dizisi $Z_j^{m,\tau}\{z(j), z(j + \tau), z(j + (m - 1)\tau)\}, j = 1, 2, \dots, N - (m - 1)\tau$ τ gecikme zamanı ve m gömülü uzunluk kullanılarak $\{z(k), k = 1, 2, \dots, N\}$ kullanılarak elde edilir. Bir alt vektör bağımsız bir durum örüntüsü ise, ε^m potansiyel durum örüntüleri vardır. Çünkü $Z_j^{m,\tau}$ vektör dizisinin m üyesi ve her üyenin de ε olası sembolü vardır. Gömülü vektörünün durumu $q_a^{\varepsilon,m,\tau}$ olarak ifade edilebilir. Bu nedenle, potansiyel durum örüntüsü $P(q_a^{\varepsilon,m,\tau})$ 'nın olasılığını denklem 3.37'deki gibi hesaplanabilir.

$$P(q_a^{\varepsilon,m,\tau}) = \frac{|\{j: j \leq N - (m-1)\tau, \text{type}(Z_j^{\varepsilon,m,\tau}) = q_a^{\varepsilon,m,\tau}\}|}{N - (m-1)\tau} \quad (3.37)$$

burada sırasıyla $\text{type}(\cdot)$, sembol uzayından durum örüntü uzayına giden haritayı, $\|\cdot\|$ ise bir kümenin kardinalitesini temsil etmektedir.

(iii) Durum geçişlerini oluşturulur ve ardından her birinin olasılıkları hesaplanır. Sembol zaman serilerinin cebirsel yapısı, geçişlerle birbirine bağlanan sonlu bir dizi durumdan oluşur. Bu, sembol zaman serisinin zamanla birlikte bir durumdan diğerine (kendi kendine döngüler dahil) hareket ettiği anlamına gelmektedir. Ardından, durum geçişi, bir sonraki duruma gelecek sembolüdür. Durum örüntüsü $q_a^{\varepsilon,m,\tau} (a = 1, 2, \dots, \varepsilon)$ gözlendiğinde, durum geçiş olasılığı, denklem 3.38'deki gibi $\sigma_b (b = 1, 2, \dots, \varepsilon)$ sembolünün koşullu olasılığıdır.

$$P(\sigma_b | q_a^{\varepsilon,m,\tau}) = P\{z(j + m\tau) = \sigma_b | j: j \leq N - m\tau, \text{type}(Z_j^{\varepsilon,m,\tau}) = q_a^{\varepsilon,m,\tau}\} \quad (3.38)$$

Burada $a = 1, 2, \dots, \varepsilon^m$ ve $b = 1, 2, \dots, \varepsilon$ olarak seçilir. ε sembollerin sayısını ve ε^m ise durumların sayısını temsil eder. Koşullu olasılık koşulu karşılamaktadır ($\sum_{b=1}^{\varepsilon} P(\sigma_b | q_a^{\varepsilon,m,\tau}) = 1$). $P(\sigma_b | q_a^{\varepsilon,m,\tau})$ de yeniden yazılırsa denklem 3.39 elde edilir.

$$P(\sigma_b | q_a^{\varepsilon, m, \tau}) = \frac{|\{j: j \leq N - m\tau, \text{type}(z_j^{\varepsilon, m, \tau}) = q_a^{\varepsilon, m, \tau}, z(j + m\tau) = \sigma_b\}|}{N - m\tau} \quad (3.39)$$

(iv) Shannon entropisine kullanılarak, SyDyEn durum entropisi ile durum geçiş entropisinin toplamı olarak denklem 3.40'daki gibi tanımlanır.

$$\begin{aligned} \text{SyDyEn}(X, m, \tau, \varepsilon) = & - \sum_{a=1}^{\varepsilon^m} P(q_a^{\varepsilon, m, \tau}) \cdot \ln P(q_a^{\varepsilon, m, \tau}) - \\ & \sum_{a=1}^{\varepsilon^m} \sum_{b=1}^{\varepsilon} P(q_a^{\varepsilon, m, \tau}) \cdot \ln P(q_a^{\varepsilon, m, \tau}) \cdot P(\sigma_b | q_a^{\varepsilon, m, \tau}) \end{aligned} \quad (3.40)$$

Denklem 3.40 kullanılarak $\text{SyDyEn}(X, m, \tau, \varepsilon)$ entropisinin maksimum değerinin $\ln(\varepsilon^{m+1})$ olduğu da bulunabilir. Bu, tüm olası durumların ve durum geçişlerinin eşit ve $P(q_a^{\varepsilon, m, \tau}) = 1/\varepsilon^m$ ve $P(\sigma_b | q_a^{\varepsilon, m, \tau}) = 1/\varepsilon$ olasılığına sahip olduğu anlamına gelir. Daha sonra, $\ln(\varepsilon^{m+1})$ ile normalizasyon yapılan SyDyEn denklem 3.41 aşağıdaki gibi ifade edilebilir.

$$\text{SyDyEn}(X, m, \tau, \varepsilon) = \text{SyDyEn}(X, m, \tau, \varepsilon) / \ln(\varepsilon^{m+1}) \quad (3.41)$$

Burada $0 \leq \text{SyDyEn}(X, m, \tau, \varepsilon) \leq 1$ koşulunun sağlanması gerekmektedir. SyDyEn değerinin büyümesi ile zaman serisinin daha rastgele ve düzensiz olurken, küçüldükçe zaman serisi daha düzenli ve periyodik davranış sergiler (Li ve ark., 2017).

• Artış Entropisi (IncrEn)

Increment Entropy (IncrEn) yaklaşımında, bir zaman serisinin karmaşıklığı, doğal dalgalanmalarını yansıtmak için ardışık öğeler arasındaki varyasyonların işaretlerinin ve boyutlarının kodlanmasıyla elde edilir. N boyutlu $x(i)$ zaman serisinin IncrEn hesaplanması 6 adımda gerçekleştirilebilir (Liu ve ark., 2018).

- (i) Artımlı zaman serisi $\{v(j), 1 \leq j \leq N - 1\}$ orijinal zaman serisi $\{x(i)\}$ kullanılarak oluşturulur.
- (ii) $\{v(i)\}$ artımlı zaman serisini m noktalı vektörlere bölünür. m , IncrEn hesaplamadan önce sabitlenir. Bu bölme işleminden sonra $N - m$ tane $v(l) = [v(l), \dots, v(l + m - 1)], 1 \leq l \leq N - m$ artış vektörü elde edilir.

(iii) Daha sonra, her bir artış vektörü $v(l)$ için örüntü vektörü w_l hesaplanır. Burada ilk olarak işaretin $s_k = \text{sgn}(v(k))$ olduğu ve q_k boyutunun q ile $|v(j) \times q / \text{std}(\{v(j)\})|$ arasındaki minimuma veya $\text{std}(\{v(j)\}) = 0$ olan her öge için eşlenen kelime hesaplanır. Bu arada q parametresi de *IncrEn* hesaplamadan önce sabitlenir. w_l parametresi kendisine karşılık gelen tüm s_k ve q_k çiftlerinin birleşimi alınarak oluşturulur.

(iv) $\{v(j)\}$ 'deki her benzersiz w_n kelimesinin toplam örnek sayısını $Q(w_n)$ hesaplanır.

(v) Her benzersiz kelimenin göreceli frekansı $P(w_n) = Q(w_n) / N - m$ bulunur.

(vi) Sonuncu olarak, verilen zaman serisinin *IncrEn* değeri denklem 3.42 kullanılarak bulunur.

$$\text{IncrEn} = -\frac{1}{m-1} \sum_{n=1}^{(2q+1)^m} P(w_n) \cdot \log P(w_n) \quad (3.42)$$

• Kosinüs Benzerlik Entropisi (CosiEn)

Cosine Similarity Entropy (CosiEn), serilerin düzensizliğini belirlemek ve tutarlı bir entropi tahmini için geliştirilmiştir. CosiEn açısal mesafe, Shannon entropisi ve kaba taneli ölçek (coarse-grained scale) aracılığıyla hesaplanan gömülü vektörlerin benzerliğine dayalı bir yöntemdir. M gömülü boyutlu, toleransı r_{CosiEn} ve τ gecikme zamanı ile verilen bir $\{x(i)\}_{i=1}^N$ CosiEn yaklaşımın adımları aşağıda verilmiştir (Chanwimalueang, T., ve Mandic, D. P., 2017).

(i) (İsteğe bağlı ön işleme) Ofseti kaldırılır ve sıfır medyan serisi denklem 3.43'deki gibi oluşturulur ($\{g(i)\}_{i=1}^N$).

$$g(i) = x_i - \text{median}(\{x(i)\}_{i=1}^N) \quad (3.43)$$

(ii) $x_i^{(m)}$ gömülü vektörler, $\{x(i)\}_{i=1}^N$ veya $\{g(i)\}_{i=1}^N$ 'den oluşturulur.

$$x_i^{(m)} = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}] \text{ or } x_i^{(m)} = [g_i, g_{i+\tau}, \dots, g_{i+(m-1)\tau}] \quad (3.44)$$

(iii) Tüm çift gömülü vektörler için açısal mesafe denklem 3.45 gibi hesaplanır.

$$AngDis_{i,j}^{(m)} = \frac{1}{\pi} \cos^{-1} \left(\frac{x_i^{(m)} \cdot x_j^{(m)}}{|x_i^{(m)}| \cdot |x_j^{(m)}|} \right), i \neq j \quad (3.45)$$

(iv) Benzer örüntülerin sayısı $P_i^{(m)}(r_{CosiEn})$, $AngDis_{i,j}^{(m)} \leq r_{CosiEn}$ kriteri karşılandığında hesaplanır.

(v) $B_i^{(m)}(r_{CosiEn})$, benzer kalıpların oluşma yerel olasılığını denklem 3.46'daki gibi hesaplanır.

$$B_i^{(m)}(r_{CosiEn}) = \frac{1}{(N-m-1)} P_i^{(m)}(r_{CosiEn}) \quad (3.46)$$

(vi) Nihai olarak $CosiEn$ denklem 3.47 kullanılarak hesaplanır.

$$CosiEn(m, \tau, r_{CosiEn}, N) = -[B^m(r_{CosiEn}) \log_2 B^m(r_{CosiEn}) + (1 - B^m(r_{CosiEn})) \log_2 (1 - B^m(r_{CosiEn}))] \quad (3.47)$$

• Faz Entropisi (PhasEn)

İki boyutlu bir faz alanı olan ikinci dereceden fark grafiği (The second-order difference plot , SODP), değişkenlik oranının görsel bir özetini sunar. Phase entropy: (PhasEn), bir SODP'deki bir sinyalin dağılımını ölçülerek geliştirilmiştir. PhasEn hesaplanması için aşağıdaki adımlar gerçekleştirilmiştir (Rohila ve Sharma, 2019).

(i) Verilen bir $g(n)$ zaman serisinden sırasıyla, $Y[n]$ ve $X[n]$ hesaplanmıştır ve $X[n]$ 'e karşı $Y[n]$ dağılım(scatter) grafiği denklem 3.48 ve denklem 3.49'deki gibi oluşturulmuştur.

$$Y[n] = g(n+2) - g(n+1) \quad (3.48)$$

$$X[n] = g(n+1) - g(n) \quad (3.49)$$

(ii) Her saçılma (scatter) noktasının eğim açısını hesaplanılır. $0 - 2\pi$ eğim açılarının açıklığını elde etmek için dört çeyrek daireli(quantant) bir arctan fonksiyonu kullanılır.

$$Y[n] = \tan^{-1} \frac{Y[n]}{X[n]} \quad (3.50)$$

(iii) Düzlemi k sektöre bölerek, her sektör içindeki kümülatif eğimi (S_θ) elde edilir.

$$S_\theta[i] = \sum_{j=1}^{M_i} \theta[j], i = 1, 2, \dots, k \quad (3.51)$$

Burada M_i i. sektördeki nokta sayısını göstermektedir.

(iv) Olasılık dağılımı $p(i)$ 'yi elde etmek için, her sektör içindeki kümülatif toplam ($S_\theta[i]$)'yı, tüm $\sum_{i=1}^k S_\theta[i]$ düzleminin kümülatif eğimine bölünür.

(v) $p(i)$ kullanılarak hesaplanan Shannon entropisi ile *PhasEn* denklem 3.52'deki gibi elde edilir.

$$\text{PhasEn} = -\frac{1}{\log k} \sum_{i=1}^k p(i) \cdot \log p(i) \quad (3.52)$$

• Eğim Entropisi (SlopEn)

SlopEn'in amacı, bir şekilde, girdi zaman serilerinin başka türlü sembolik temsiline genlik bilgisini dahil etmektir. Bir giriş zaman serisi $x = \{x_0, x_1, x_2, \dots, x_{N-1}\}$ verilmiş olsun. Burada x_i , i. genlik örneği, N örnek sayısını gösterir. j örneği ile başlayan m uzunluğunda x 'in bir alt dizisi $x_j^m = \{x_j, x_{j+1}, \dots, x_{j+m-1}\}$, x_j^m ile ilişkili bir sembolik örüntünün hesaplanması gerekir. Bu amaçla, iki eşik de tanımlanır: γ , ve δ ($\gamma > \delta > 0$). Böylece, alt dizinin ardışık iki örneği arasındaki fark $d = x_{j+1} - x_j$ olarak tanımlanırsa, her sembol:

- ✓ Eğer $d > \gamma$ ise, sembol 2'dir.
- ✓ Eğer $d \leq \gamma$ ve $d > \delta$ ise, sembol 1'dir (45° açının altında ve $\gamma=1$ olduğunda 0 bölgesinin üstünde).
- ✓ Eğer $|d| \leq \delta$ ise, sembol 0'a atanır.

- ✓ Eğer $d < -\delta$ ve $d \geq -\gamma$ ise, sembol -1'dir.
- ✓ Eğer $d < -\gamma$ ise, sembol -2'dir.

Bir alt dizi için tüm semboller hesaplandıktan sonra, örnek j 'ye kadar bulunan tüm farklı örüntüleri içeren bir dinamik liste kullanılırken, elde edilen örüntünün göreceli frekansı her defasında güncellenir (Cuesta-Frau, 2019).

- **Izgaralı Dağılım Entropisi (GridEn)**

Gridded Distribution Entropy (GridEn), bir Poincaré grafiğinin ızgaralı bir tanımlayıcısı olarak tanımlanır. Poincaré grafiği, bir zaman serisinin ilerlemesini geometrik olarak haritalamak için kullanılan iki boyutlu faz uzay diyagramıdır. Gridded Distribution Entropy (GridEn), her bir ızgaradaki nokta sayısının Shannon entropisini tahmin etmektedir. GridEn bulunması için öncelikle sabit örnekleme frekansına sahip bir $X\{x(i), i = 1, 2, \dots, N\}$ zaman serisi, $[0,1]$ aralığında min-max yöntemi kullanılarak aşağıdaki gibi normalizasyon işlemine tabi tutulur (Yan ve ark., 2019).

$$x_{norm}(i) = \frac{x(i) - \min(X)}{\max(X) - \min(X)} \quad (3.53)$$

Daha sonra Poincaré grafiği X_{norm} için oluşturulmuştur. Her potansiyel n yatay ızgara çizgisi ve n dikey ızgara çizgisi için, Izgaralı Dağıtım Oranı (Gridded Distribution Rate, GDR), ızgaranın iyi uyumunun bir indeksidir. The Gridded Distribution Rate (GDR), en az bir nokta (α) ile doldurulmuş tüm hücrelerin (n^2)'ye oranıdır.

$$GDR = \frac{\alpha}{n^2} \quad (3.54)$$

Daha sonra, gridlenmiş Poincaré grafiğindeki j 'inci grid için noktaların frekansını belirleyen P_j olasılığı denklem 3.55 ile tanımlanır.

$$P_j = \frac{b}{N-1} \quad (3.55)$$

Burada b griddeki nokta sayısıdır. Ve sonuç olarak Shannon entropi formülü kullanılarak Denklem 3.56 ile *GridEn* hesaplanır.

$$GridEn = - \sum_{j=1}^{n^2} P_j \cdot \log P_j \quad (3.56)$$

- **Baloncuk Entropisi (BubbEn)**

Kabarcık entropisi (BubbEn) yaklaşımı yok denecek kadar az parametreye sahiptir. *BubbEn*'de, bir $x[i]$ vektörünü sıralamak için bir kabarcık sıralama algoritması kullanılır vektörü artan düzende sıralamak için gereken takas sayısı sayılır. Aynı sıralama çabası içerisinde olan vektörler birlikte gruplandırılır ve bu vektörler kullanılarak koşullu Rényi entropisi hesaplanır. Böylelikle benzersiz durumların sayısı azaltılır. Olasılık dağılımı $p(i)$ denklem 3.57 kullanılarak hesaplanabilir.

$$p(i) = \frac{\text{Number of swaps required for sorting } x[i]}{N-m+1} \quad (3.57)$$

Daha sonra *BubbEn*, $p(i)$ 'nin koşullu Rényi entropisi olarak denklem 3.58'deki gibi tanımlanır.

$$BubbEn = \frac{H_{swaps}^{m+1} - H_{swaps}^m}{\log\left(\frac{m+1}{m-1}\right)} \quad (3.58)$$

Burada $H_{swaps}^{m+1} = - \log \sum_{i=2}^{N-m+1} p(i)^2$ kullanılarak bulunur (Manis ve ark., 2017).

- **Entropinin Entropisi (EnofEn)**

Entropy of Entropy (EnofEn), bir sinyalin karmaşıklığını ölçmek için kullanılır. Analiz, Multiscale (MSE)'nin özelliklerini birleştirir, ancak daha az veri gerekir ve süper bilgi adı verilen bilgiyi değerlendirmenin alternatif bir yolunu sunar (Hsu ve ark., 2017). EnofEn analizinin ilk adımında, ilk olarak N uzunluğundaki tek boyutlu ayırık zaman serisi $x_i = \{x_1, \dots, x_N\}$ ardışık örtüşmeyen $w_j^{(\tau)}$ pencerelerine böleriz. Her $w_j^{(\tau)}$ penceresi, τ uzunluğundadır; burada $w_j^{(\tau)} = \{x_{(j-1)\tau+1}, \dots, x_{(j-1)\tau+\tau}\}$, $j = 1, \dots, N/\tau$ (*window index*) ve τ , MSE analizinde ölçek faktörünü temsil etmektedir.

Daha sonra Shannon Entropi denklemi kullanılarak her pencerenin değeri bulunur. Olasılık dağılımı p_{jk} denklem 3.59 ile bulunabilir.

$$p_{jk} = \frac{\text{total number of } x_i \text{ over } w_j^{(\tau)} \text{ in state } k}{\tau} \quad (3.59)$$

Burada k 1'den s_1 kadar durum indeksini göstermektedir.

Sonuç olarak, $w_j^{(\tau)}$ penceresinin Shannon entropi değeri $y_j^{(\tau)}$ denklem 3.60 ile elde edilebilir.

$$y_j^{(\tau)} = -\sum_{k=1}^{s_1} p_{jk} \cdot \log p_{jk} \quad (3.60)$$

Her pencere için aynı işlemi tekrarlanarak, her orijinal zaman serisi için N/τ temsili durumların bir Shannon entropi dizisi $y_j^{(\tau)}$ oluşturulur. EoE'nin ikinci adımında, orijinal zaman serisi x_i 'nin EnofEn değeri olarak $y_j^{(\tau)}$ 'nin değişim derecesini ölçmek için tekrar Shannon entropisi kullanılır. $y_j^{(\tau)}$ dizisi üzerindeki $w_j^{(\tau)}$ penceresinin belirli bir temsili durumu $y_j^{(\tau)}$ 'nin l düzeyinde meydana gelme olasılığı p_l denklem 3.61 ile elde edilebilir.

$$p_l = \frac{\text{total number of } y_j^{(\tau)} \text{ over } y_j^{(\tau)} \text{ in level } l}{N/\tau} \quad (3.61)$$

Burada l 1'den s_2 'e kadar seviye indeksini göstermektedir. Sonuç olarak, $y_j^{(\tau)}$ dizisinin ortaya çıkan Shannon entropi değeri, orijinal zaman serisi x_i 'nin EnofEn değeri denklem 3.62 kullanılarak bulunabilir.

$$\text{EnofEn} = -\sum_{l=1}^{s_2} p_l \cdot \log p_l \quad (3.62)$$

- **Dikkat Entropisi (AttnEn)**

Attention Entropy (AttnEn) yalnızca temel gözlemlere dikkate alan kavramsal olarak yeni bir yaklaşımdır. Bu yöntem tüm gözlemlerin frekansını saymak yerine, bir zaman

serisindeki temel gözlemler arasındaki aralıkların frekans dağılımını analiz eder. $AttnEn$ ayarlanması için herhangi bir parametreye ihtiyaç duymaz. Zaman serisi uzunluğuna bağlı değildir ve hesaplamalar yalnızca doğrusal zaman ile gerçekleştirilebilir. $AttnEn$ üç ana adımda hesaplanır:

- (i) Anahtar örüntüler tanımlanır.
- (ii) İki ardışık anahtar örüntü arasındaki aralıklar hesaplanır.
- (iii) Aralıkların Shannon entropisini bulunur.

Sonlu bir X dizisi için önce anahtar örüntü Ω tanımlanır. İkinci olarak, Ω örüntüsünde u_i ve u_j eşleşmesini sağlayan X 'in herhangi bir alt dizisi u_i u_k ve u_j için $I^\Omega = \{v | v = j - i\}$ aralıklarını bulunur. Burada u_k alt dizisi herhangi bir $i < k < j$ kriteri için Ω 'de eşleşmez.


Sonuç olarak I^Ω $AttnEn$ olarak hesaplanır (Yang ve ark., 2020).

3.2.2. Aşırı öğrenme makinası

Aşırı öğrenme makinesi (Extreme Learning Machine, ELM) Huang ve arkadaşları (2006) tarafından geliştirilmiştir. ELM modeli giriş ağırlıkları rastgele çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir YSA modeli olarak ifade edilmektedir. ELM de gizli katmanda sigmodial, sine, Gaussian ve hard-limitin gibi aktivasyon fonksiyonları kullanılırken çıkış katmanda doğrusal fonksiyon kullanılmaktadır. ELM modeli türevlenemeyen veya kesikli aktivasyon fonksiyonlar kullanılabilir (Suresh ve ark., 2010). Geleneksel ileri beslemeli yapay sinir ağlarında ağırlıklar ve eşik değerleri gibi parametrelerin gradyan bazlı öğrenme algoritmaları ile güncellenmesi gerekmektedir. Ancak iyi performansın sağlanması için öğrenme süreci hem zaman almakta hem de hata yerel bir noktaya takılabilmektedir. Momentum değerinin değiştirilmesi belki hatanın lokal bir noktaya takılmasını engelleyebilir ancak öğrenme sürecinin uzun sürmesi etkilemeyecektir. Tek gizli katmanlı ileri beslemeli bir ağda giriş-çıkış ağırlıkları ve eşik değerleri ağırlık performansını etkilememektedir ELM modelinde giriş ağırlıkları ve eşik değerleri rastgele üretilmekte fakat çıkış ağırlıkları hesaplanmaktadır (Huang ve ark., 2006).

Bu yüzden ELM geleneksel yöntemlere göre bazı görevlerde daha iyi performanslı ve hızlı olduğu bilinmektedir. ELM ağı tek gizli katmanlı ileri beslemeli bir

Yapay Sinir Ağı (Artificial Neural Network, ANN) modelin özelleştirilmiş halidir. Şekil 3.11’de tek gizli katmanlı ileri beslemeli bir Yapay Sinir Ağı gösterilmiştir.



Şekil 3. 11. İleri beslemeli yapay sinir ağı

Şekilde $X=(X_1,X_2,X_3,...X_N)$ giriş ve Y çıkış özelliklerini belirtmek üzere, gizli katmanda M nörona sahip ağın matematiksel ifadesi aşağıdaki denklem 3.63 gibi belirtilir (Suresh ve ark., 2010).

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = O_k \quad , \quad k = 1, 2, \dots, N \quad (3.63)$$

burada $W_i=(W_{i1},W_{i2},...,W_{in})$ giriş katmandaki $\beta_i=(\beta_{i1},\beta_{i2},...,\beta_{im})$ çıkış katmandaki ağırlıkları, b_i gizli katman nöronların eşik değerlerini ve O_k çıkış değerlerini belirtir. $g(.)$ aktivasyon fonksiyonudur.

N giriş özellikli bir ağda amaç hatanın $\sum_{k=1}^N (o_k - Y_k) = 0$ veya $\sum_{k=1}^N (o_k - Y_k)^2 = 0$ hatanın elde edilmesidir. Dolayısıyla denklem 3.64 gibi yazılabilir (Huang ve ark., 2006).

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = Y_k \quad , \quad k = 1, 2, 3 \dots N \quad (3.64)$$

Yukarıdaki eşitlikte,

$$H\beta=Y \quad (3.65)$$

Yazılabilir. Burada

$$H(W_1, \dots, W_M; b_1, \dots, b_M; X_1, \dots, X_M) = \begin{bmatrix} g(W_1 X_1 + b_1) & \cdots & g(W_M X_M + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \cdots & g(W_M X_N + b_M) \end{bmatrix} \quad (3.66)$$

ve

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix} \quad \text{ve} \quad Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_M^T \end{bmatrix} \quad (3.67)$$

şeklinde ifade edilebilir (Suresh ve ark., 2010).

Burada H gizli katman çıkış matrisidir. ELM’de giriş ağırlıkları $W_i=(W_{i1}, W_{i2} \dots W_{in})$ ve b_i gizli katman nöronların eşik değerleri rastgele üretilmekte ve H gizli katman çıkış matrisi analitik olarak elde edilmektedir. Geleneksel ileri beslemeli bir YSA da ağırların eğitilmesi, ELM’de $H\beta=Y$ doğrusal denklemde en küçük kareler çözümünün aranmasıdır. ELM algoritması üç adımda aşağıdaki gibi özetlenebilir (Liang ve ark., 2006).


1. Aşama: $W_i=(W_{i1}, W_{i2} \dots W_{in})$ giriş ağırlıkları ve gizli katman b_i eşik değerleri rastgele üretilir.
2. Aşama: H gizli katman çıkış hesaplanır.
3. Aşama: β çıkış ağırlıkları $\beta=H+Y$ göre hesaplanır. Y hedef özelliştir.

3.2.3. Rulman arızalarının tespiti için 1d-lbp ile hibrit derin öğrenme tabanlı yaklaşım

3.2.3.1. Min-max(mm) 1d-lbp

Bu çalışmada rulman titreşim sinyallerinden arıza tespiti için sinyal üzerindeki değerler arasındaki yerel değişimleri dikkate alan yeni bir öznitelik çıkarım yaklaşımı önerilmiştir. Bu yaklaşım tek boyutlu rulman titreşim sinyallerine uygulanmıştır. MM-1D-LBP yöntemi Şekil 3.12’de belirtilen rulman titreşim sinyal parçası üzerinde detaylıca

anlatılmıştır. MM-1D-LBP sinyal üzerinde noktasal olarak ilerleyen, pencere boyutu WS=9 olan pencere içerisine giren değerler üzerinden gerçekleştirilmektedir. Herhangi bir zamanda WS=9 pencere içerisine giren değerler 9 adet değer olarak vektörel şekilde $P=\{P_c, P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\}$ ifade edilmektedir.



Şekil 3. 12. MM-1D-LBP yönteminin anlatımı için örnek titreşim sinyal parçası

WS pencere içerisine giren 9 değer sırası ile biri P_c (Point Center) ve diğerleri komşu $P=\{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\}$ değerler olarak kabul edilir. P_c değeri sırası ile WS penceresine giren vektör üzerindeki her değer olmaktadır. Bu durum Şekil 3.12.'de gösterilmiştir. Şekil 3.13.'te görüldüğü gibi olası 9 durum bulunmaktadır. Daha sonra P_c değeri diğer değerler ile aşağıdaki denklem 3.68 kullanılarak ikili karşılaştırmalar yapılmaktadır.

$$1D - LBP = \begin{cases} P_c > P_i & 1, & P_i = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\} \\ P_c \leq P_i & 0, & P_i = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8\} \end{cases} \quad (3.68)$$

Şekil 3.13.'ten görüldüğü gibi olası 9 durumdan dolayı 9 adet $1D - LBP$ değeri elde edilmektedir. $1D - LBP$ değerleri 0-255 arasındaki değerlerden oluşmaktadır. $MM - 1D - LBP$ yöntemi rulman titreşim sinyali üzerindeki tüm noktalara uygulanmaktadır. Dolayısıyla her nokta için 9 adet $1D - LBP$ değeri elde edilmektedir.

Pc	P1	P2	P3	P4	P5	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₁
P1	Pc	P2	P3	P4	P5	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₂
P1	P2	Pc	P3	P4	P5	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₃
P1	P2	P3	Pc	P4	P5	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₄
P1	P2	P3	P4	Pc	P5	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₅
P1	P2	P3	P4	P5	Pc	P6	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₆
P1	P2	P3	P4	P5	P6	Pc	P7	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₇
P1	P2	P3	P4	P5	P6	P7	Pc	P8	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₈
P1	P2	P3	P4	P5	P6	P7	P8	Pc	
-0.0623	-0.2740	0.0370	-0.0962	0.0508	-0.1215	-0.2388	0.1090	-0.0975	1D-LBP ₉

Şekil 3. 13. Olası 1D-LBP Operatörler

Yukarıdaki sinyal parçası örneği için 1D-LBP değerleri {1D-LBP₁, 1D-LBP₂, 1D-LBP₃, 1D-LBP₄, 1D-LBP₅, 1D-LBP₆, 1D-LBP₇, 1D-LBP₈, 1D-LBP₉} denklem 3.68'e göre {173, 0, 237, 77,253, 68, 64, 255, 70} değerleri elde edilmektedir.

MM-1D-LBP yönteminde oluşan 1D-LBP_i değerlerinden 5 farklı 1D-LBP operatörü oluşturulmaktadır. Bu operatörler aşağıdaki eşitlikler ile ifade edilmiştir. Min ve max haritaları ile farklı operatörler oluşturulmuştur.

$$1D - LBP = 1D - LBP_5 \quad (3.69)$$

$$1D-LBP_{min} = \min\{1D-LBP_1, 1D-LBP_2, 1D-LBP_3, 1D-LBP_4, 1D-LBP_5, 1D-LBP_6, 1D-LBP_7, 1D-LBP_8, 1D-LBP_9\} \quad (3.70)$$

$$1D-LBP_{max} = \max(1D-LBP_1, 1D-LBP_2, 1D-LBP_3, 1D-LBP_4, 1D-LBP_5, 1D-LBP_6, 1D-LBP_7, 1D-LBP_8, 1D-LBP_9) \quad (3.71)$$


$$1D-LBP_{difMin} = 1D-LBP - 1D-LBP_{min} \quad (3.72)$$

$$1D-LBP_{difMax} = 1D-LBP_{max} - 1D-LBP \quad (3.73)$$

Her bir 1D-LBP operatörü sinyalin uzamsal bilgisini sağlayamasa da kombinasyonları sinyal üzerindeki değerlerin uzamsal dağılımı ve organizasyonu hakkında bilgiler içermektedir. 1D-LBP_{min} ve 1D-LBP_{max} olmak üzere iki yeni LBP


operator haritası oluşturmak için oluşan 1D-LBPi değerlerin minimum ve maksimum değerleri kullanılmaktadır. 1D-LBPdifMin ve 1D-LBPdifMax haritalarına ait değer aralığı 0-255 arasındadır. 1D-LBPmin, 1D-LBPmax, 1D-LBPdifMin ve 1D-LBPdifMax dört haritanın farklı uzaysal dağılım gösterir.

Örnek rulman titreşim sinyaline MM-1D-LBP yönteminin uygulanması sonucu Şekil 3.14.'deki sinyaller oluşmaktadır.



Şekil 3. 14. 1D-LBPmin, 1D-LBPmax, 1D-LBPdifMin ve 1D-LBPdifMax operatörlerinin sinyale uygulanması. (A) 1D-LBP5, (B) 1D-LBPmin, (C) 1D-LBP-max, (D) 1D-LBPDifmax, (E) 1D-LBPDifmin

Oluşan bu sinyallere ait histogramlar kullanılarak rulman arıza teşhisi gerçekleştirilmiştir. Bu sinyallere ait histogramlar 1D-CNN ve LSTM hibrit modeline giriş olarak verilmiştir. Sinyallere ait histogramlar aşağıda şekil 3.15.'te verilmiştir.



Şekil 3. 15. 1D-LBP5,1D-LBPmin, 1D-LBPmax, 1D-LBPdifMin ve 1D-LBPdifMax sinyallere ait histogramlar.


3.2.3.2. 1D-CNN

1D-CNN, sıralı verilerin analizi ve işlenmesinde kullanılan bir yapay sinir ağı mimarisidir. Geleneksel evrişimli sinir ağı (CNN) mimarisinin 1 boyutlu verilere özelleştirilmiş bir versiyonudur (Wang ve ark., 2021). 1D-CNN, zaman serileri, metinler veya diğer sıralı veri türlerinde kullanılarak etkili sonuçlar vermektedir. 1D-CNN'nin temel bileşenleri evrişim katmanları (convolutional layers) ve havuzlama katmanları (pooling layers) olarak adlandırılır. Evrişim katmanları, belirli boyutlara sahip evrişim filtrelerini kullanarak verinin farklı özelliklerini yakalamayı sağlar. Bu evrişim filtreleri, verinin belirli bölgelerine uygulanarak özellik haritaları (feature maps) oluşturulur (Shan ve ark., 2023). Her bir özellik haritası, filtre tarafından vurgulanan belirli bir özelliği temsil eder. Havuzlama katmanları, elde edilen özellik haritalarının boyutunu küçültmek ve özetlemek için kullanılır. Bu katmanlar, özellik haritalarının alt örneklemelerini alarak en önemli özelliklerin korunmasını sağlar. Bu süreç, modelin daha özgün ve anlamlı özellikleri tanımasına yardımcı olur. 1D-CNN'nin başarısı, evrişim katmanlarının sayısı, evrişim filtrelerinin boyutları, aktivasyon fonksiyonları, havuzlama stratejileri ve tam bağlantılı (fully connected) katmanların kullanımı gibi çeşitli faktörlere bağlıdır (Jia ve ark., 2023). Bu parametrelerin iyi ayarlanması, modelin veri üzerinde etkili özellikler

öğrenmesini sağlar. 1D-CNN, metin sınıflandırması, duygu analizi, zaman serisi tahmini, biyomedikal veri analizi gibi birçok uygulama alanında kullanılmaktadır. Özellikle Doğal Dil İşleme (Natural Language Processing, NLP) alanında, metinlerin kelime veya karakter düzeyinde işlenmesi için etkili bir yöntem olarak kullanılmaktadır.

3.2.3.3. LSTM

Uzun Kısa Dönemli Bellek (Long Short-Term Memory - LSTM), derin öğrenme alanında yaygın olarak kullanılan bir yapay sinir ağı mimarisidir. LSTM, özellikle zaman serisi verileri ve dil işleme problemleri gibi uzun vadeli bağımlılıkların önemli olduğu problemlerde etkilidir (Dong ve ark., 2023). LSTM, geleneksel yapay sinir ağı modellerinin karşılaştığı bir sorun olan uzun vadeli bağımlılık problemini çözmek için tasarlanmıştır. Standart yapay sinir ağı modellerinde, geriye doğru yayılım sırasında türevlerin sürekli olarak çarpılması sonucu gradient kaybı veya patlaması sorunu ortaya çıkabilir. Bu da modelin uzun vadeli bağımlılıkları yakalamasını zorlaştırır. LSTM, bu sorunu hafifletmek için özel bir hücre yapısı kullanır (Vos ve ark., 2022). LSTM hücresi, üç ana bileşenden oluşur: giriş kapısı (input gate), unutma kapısı (forget gate) ve çıkış kapısı (output gate). Giriş kapısı, hangi bilgilerin güncellenmesi gerektiğini belirlerken, unutma kapısı geçmiş bilgilerin nasıl unutulacağını kontrol eder. Çıkış kapısı ise güncellenmiş bilgilerin ne zaman çıkış olarak kullanılacağını belirler. Bu bileşenler, LSTM'in uzun vadeli bağımlılıkları yakalayabilmesini ve geçmiş bilgileri doğru bir şekilde kullanabilmesini sağlar. LSTM tekrarlayan sinir ağının yapısı, etkileşimli sinir ağı yapısının dört katmanını içeren Şekil 10'da gösterilmiştir. Her bir bileşenin işlevi aşağıdaki formüllerle ifade edilebilir (Sun ve ark., 2023).



Şekil 3. 16. LSTM hücre yapısı

Giriş Kapısı (Input Gate):

$$i_t = \sigma(W_i x_t + W_{hi} h_{t-1} + b_i) \quad (3.74)$$

Unutma Kapısı (Forget Gate):

$$f_t = \sigma(W_f x_t + W_{fi} h_{t-1} + b_f) \quad (3.75)$$

Bellek Hücresi Güncellemesi:

$$\tilde{C}_t = \tanh(W_c x_t + W_{hc} h_{t-1} + b_c) \quad (3.76)$$

Çıkış Kapısı (Output Gate):

$$o_t = \sigma(W_o x_t + W_{oi} h_{t-1} + b_o) \quad (3.77)$$


Hücre Çıkışı:

$$h_t = o_t \otimes \tanh(C_t) \quad (3.78)$$

Burada, i_t , f_t , o_t : sırasıyla giriş, unutma ve çıkış kapılarının çıktılarıdır. $\tilde{C}_t$: güncellenmiş bellek hücresidir. h_t : hücrenin çıkışıdır. x_t : mevcut zaman adımında gelen giriş verisidir. W_i , W_f , W_o , W_c : ağırlık matrisleri. b_i , b_f , b_o , b_c : bias terimleri. σ : sigmoid aktivasyon fonksiyonu. $\tanh$: hiperbolik tanjant aktivasyon fonksiyonunu belirtir (Ravikumar ve ark., 2021).

3.2.3.4. Önerilen yaklaşım

Rulman titreşim sinyallerinden arıza tespiti için önerilen yaklaşım 4 aşamadan oluşmaktadır. Bu yaklaşıma ait sistem diyagramı Şekil 3.17.'de verilmiştir. Her aşamada gerçekleştirilen işlemler kısaca verilmiştir.




Şekil 3. 17. Rulman arıza teşhis diyagramı

Block 1: İki farklı titreşim veri seti toplatılmıştır. Birinci veri seti rulmanların farklı bölgelerinde bulunan arıza türlerin tespiti için oluşturulmuştur. İkinci veri seti ise rulmanlarda meydana gelen arızaların boyutunun tahmini için oluşturulmuştur.

Block 2: Bu bölümde rulman titreşim sinyallere MM-1D-LBP yöntemi uygulanmıştır. MM -1D-LBP yönteminin bir sinyale uygulanması sonucunda birbirinden farklı 5 sinyal oluşmaktadır. Her sinyal üzerindeki değerler 0-255 arasında değişim göstermektedir.

Block 3: Bir önceki aşamadan gelen MM-1D-LBP histogramları LSTM ve 1D-CNN ağlarından oluşturulmuş hibrit bir modele verilmektedir. Bu blok sınıflandırma aşamasıdır. Hibrit modele ait grafik Şekil 3.18.'de gösterilmektedir. Modelin kanallardaki 1dConv katmanlardaki filtre boyutları (FS) birbirinden farklılık göstermektedir.

Block 4: Karar aşamasıdır. Sınıflandırma başarı oranları, performans ölçütleri, karışıklık matrisleri verilmiştir.




Şekil 3. 18. Rulman titreşim sinyallerin sınıflandırılması için LSTM ve 1D-CNN tabanlı hibrit model

3.2.4. Rulmanların kalan faydalı ömrünün tahmini için yaklaşım

3.2.4.1 Üçlü desenler yöntemi

Bu çalışmada rulman ömrünü tahmin etmek için sinyallerden öznitelik çıkarımı için 1D-TP yöntemi önerilmiştir. Yöntem görüntü işlemede kullanılan YÜD (Yerel Üçlü Desenler) yönteminden esinlenerek oluşturulmuştur. Geliştirilen yöntem bir boyutlu sinyallerden özellik çıkarımı için kullanılabilir. Bir boyutlu sinyal üzerindeki her değer kendi komşuları karşılaştırılıp elde edilen bu karşılaştırma bilgilerini öznitelik olarak kullanmaktadır (Kaya ve ark., 2014; Kuncan ve ark., 2020; Kaya, ve Ertuğrul, 2016). Sinyal üzerindeki her değer için komşuları arasında yapılan karşılaştırmalar sonucu ikili kodlar üretilmektedir. Elde edilen bu ikili kodların onluk karşılıkları yeni bir sinyal oluşturmaktadır. 1D-TP yönteminde sinyal üzerindeki her değer için komşu sayısı P kadar olmaktadır. Bir boyutlu sinyale 1D-TP yöntemi uygulandıktan sonra yeni iki farklı sinyal üretilmektedir. Her değer için öncesinde ve sonrasında $P/2$ kadar komşu alınmaktadır.

Örneğin 1D-TP yöntemine ait aşamalar Şekil 3.19.'da verilmiştir. P_c (merkez) değerin öncesinde 4 ve sonrasında 4 komşu değer alınmıştır.




Şekil 3. 19. 1D-TP yöntemin örnek sinyale uygulanması (A) Örnek titreşim işaretleri üzerindeki bir bölüm, (B) işaret değerleri, (C) merkez değerin (P_c) komşu değerler (P_i) ile karşılaştırılması, (D) Yüksek ve Düşük değerlerin ayrıştırılması (E) ikili dizgelerin onlu değerlere dönüştürülmesi

Şekil 3.19. (A)'de görüldüğü gibi merkez değerin (P_c) solundan $P_{Left} = \{P_0, P_1, P_2, P_3\}$ ve sağından $P_{Right} = \{P_4, P_5, P_6, P_7\}$ toplamda 8 komşu değer alınmıştır. P parametresi toplamda alınacak komşu sayısını belirtmektedir. Bu çalışmada $P=8$ olarak alınmıştır. 1D-TP yönteminde (β) parametresi sinyalin RMS (root mean square) değerini belirtir. Merkez değerin komşu değerler ile karşılaştırma işlemleri denklem 3.79 ile gerçekleştirilmektedir.


$$1D - TP = \begin{cases} 1 & P_c > P_i + \beta \\ 0 & P_c \leq P_c + \beta \text{ and } P_c \geq P_i - \beta \\ -1 & P_c < P_i - \beta \end{cases} \quad (3.79)$$

Üçlü desenler (β) parametresine bağlı olarak elde edilmektedir. Bu parametrenin sinyalin genliğine göre kullanıcı tarafından belirlenmektedir. Bu çalışmada bu parametre sinyalin RMS değerin katları şeklinde kullanılmıştır. Yerel değişimler $\pm\beta$ ile değişkenlik göstermektedir. Bu yüzden ele alınan farklı sinyaller için β 'nin farklı değerleri denenmelidir. Farklı örüntülerin yakalanması için β parametresi önemli olmaktadır. Buna ek olarak bu parametre bant-durma, bant genişliği veya filtresi olarak değerlendirilebilir. Bu parametre ile merkez değer $\pm\beta$ ile düzeltilmektedir. Bu yüzden Şekil 3.20.'de görüldüğü gibi her Pc değeri için komşular β parametresine göre filtrelenmektedir.



Şekil 3. 20. Farklı β değerlerine göre filtreleme

β parametresine göre filtreleme işleminden sonra Pc değeri için yapılan karşılaştırmalar ile iki farklı onlu değer üretilmektedir. Negatif olanlar ($P_c < P_i - \beta$) ile alt özellikler üretilirken, pozitif olanlar ($P_c > P_i + \beta$) ile üst özellikler elde edilir. 1D-TP yöntemin tüm sinyale uygulanmasından sonra iki farklı sinyal oluşturmaktadır. Bu farklı iki sinyal grupların histogramlarından alt-üst şeklinde iki öznetelik seti elde edilmektedir. Yeni sinyal üzerindeki değerler 0-255 arasında değişim göstermektedir. 1D-TP yönteminin örnek titreşim setlerine uygulanması sonucu elde edilen 1D-TP işaretleri ve bu işaretlerden çıkarılan alt özelliklere ait histogramlar Şekil 3.21.'de gösterilmiştir.



Şekil 3. 21. (A) Örnek bir titreşim sinyali, (B) 1D-TP dönüşümü sonucu elde edilen üst sinyaller, (C) Üst sinyaller histogramı, (D) 1D-TP dönüşümü sonucu elde edilen alt sinyaller, (E) Alt sinyaller histogramı

3.2.4.2. Önerilen yaklaşım

Bu çalışmada rulmanların titreşim sinyallerinden kalan faydalı ömürlerini tahmin etmek için yeni bir yaklaşım önerilmiştir. Önerilen yaklaşıma ait blok diyagram Şekil 5'te verilmiştir. Her blokta gerçekleştirilen işlemler kısaca aşağıda özetlenmiştir.



Şekil 3. 22. Önerilen yönteme ait blok diyagram.

Block 1: Üçlü desen dönüşümü için ham titreşim işaretlerini belirtir.

Block 2: 1D-TP yönteminin uygulandığı bloktur. Sinyallere bu yöntem uygulandıktan sonra 1D-TP sinyalleri elde edilmektedir. Bu işaretlerin değerleri 0-255 arasında değişkenlik göstermektedir. İşaretlere bu dönüşüm uygulandıktan sonra üst ve alt şeklinde iki farklı işaret elde edilmektedir.

Block 3: Bu aşamada titreşim işaretlerine 1D-TP yöntemi uygulandıktan sonra elde edilen alt ve üst işaretlerin histogramları oluşturulur. Histogramdaki her değer farklı bir örüntüyü belirtmektedir. P=8 olması durumunda 256 örüntü elde edilmektedir.

Block 4: Regresyon aşamasıdır. RUL tahmini için LSTM modeli kullanılmıştır.

3.2.5. Performans ölçütleri

3.2.5.1. Sınıflandırma performans ölçütleri

Çalışmada önerilen yöntemlerin performansını göstermek için doğruluk, hassaslık, hatırlatma ve f-ölçütleri kullanılmıştır. Bu başarı ölçütleri aşağıdaki Denklem (3.80-3.83) de olduğu gibi hesaplanmaktadır (Kaya ve ark., 2022).

$$\text{Doğruluk}(\text{Accuracy}) = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.80)$$

$$\text{Kesinlik}(\text{Precision}) = TP/(TP + FP) \quad (3.81)$$

$$\text{Duyarlılık}(\text{Recall}) = TP/(TP + FN) \quad (3.82)$$

$$F - \text{Ölçütü}(F - \text{Measure}) = 2(\text{Recall} * \text{Precision})/(\text{Recall} + \text{Precision}) \quad (3.83)$$

Bu denklemlerde T, F, P ve N sırasıyla doğruyu, yanlış, pozitif ve negatif ifade etmektedir. Örneğin, TP doğru sınıflandırılan pozitif örnek sayısını; FN ise yanlış sınıflandırılan negatif örnek sayısını göstermektedir.

Doğruluk, başarının tespiti için kullanılan en popüler ve basit yöntemdir ve bu oran doğru sınıflandırılmış (TP+TN) örnek sayısının, toplam örnek sayısına (TP+TN+FP+FN) oranı olarak tanımlanmaktadır.

Kesinlik: Sınıflandırıcı sonucunun kesinlik derecesini verir. Pozitif olarak etiketlenen örneklerin sayısının (TP) pozitif olarak sınıflandırılmış toplam örneklere (TP+FP) oranıdır.

Duyarlılık: Pozitif olarak etiketlenmiş örneklerin (TP) gerçekten pozitif olan örneklerin (TP+FN) toplam sayısına oranıdır

F-Ölçütü: Kesinlik ve duyarlılık metrikleri kullanılarak hesaplanmaktadır. Sistemin, kesinlik veya duyarlılık yönüne doğru optimize edilmesinde kullanılmaktadır.

3.2.5.2. Rul tahmini için performans ölçütleri

Bu çalışmada önerilen yaklaşımın performansını test etmek için hata kareler ortalamasının karekökü (Root Mean Squared Error, RMSE), mutlak hatalar ortalaması (Mean Absolute Error, MAE), simetrik ortalama mutlak yüzde hatası (Symmetric Mean Absolute Percentage Error, SMAPE), Göreceli Doğruluk (Relative Accuracy, RA) ve Skor (Score) fonksiyonları kullanılmıştır. Fonksiyonlara ait denklemler aşağıdaki eşitliklerde verilmiştir (Cao ve ark., 2021).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\widehat{RUL}_i - RUL_i)^2} \quad (3.84)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\widehat{RUL}_i - RUL_i| \quad (3.85)$$

$$SMAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\widehat{RUL}_i - RUL_i|}{(|\widehat{RUL}_i| + |-RUL_i|)/2} \quad (3.86)$$

$$RA = 1 - \frac{|\widehat{RUL}_i - RUL_i|}{RUL_i} \quad (3.87)$$

$$Err_i = \frac{RUL_i - \widehat{RUL}_i}{RUL_i} \times 100 \quad (3.88)$$

$$Score = \frac{1}{N-1} \sum_{i=1}^{N-1} A_i \quad (3.89)$$

$$A_i = \begin{cases} e^{-\ln(0.5)(Err_i/5)} & \text{if } Err_i \leq 0 \\ e^{\ln(0.5)(Err_i/20)} & \text{if } Err_i > 0 \end{cases} \quad (3.90)$$

Burada RUL_i gerçek rulman ömrünü belirtirken, $\widehat{RUL}_i$ tahmin edilen değerleri belirtir. RMSE, MAE ve SMAPE değerlerinin küçük tahmin edilmesi modelin performansını göstermektedir. Bunun yanında RA ve Score metriklerinin yüksek tahmin edilmesi beklenmektedir.

4. BULGULAR VE TARTIŞMA

Bu bölümde sonuçlar arıza yaklaşımlarına ait sonuçlar ve rulman ömrü tahmini yaklaşımlarına ait sonuçlar verilmiştir.

4.1. Aşırı Makine Öğrenmesi ile Entropi Varyantlarını Kullanarak Rulman Arıza Teşhisi

Bu çalışmada rulman titreşim işaretlerin sınıflandırılması için 3 farklı senaryo için denemeler gerçekleştirilmiştir. Deney 1 (Veri seti 1) için {1500, 1740, 1800, 1860 ve 2100} gibi farklı hızlarda elde edilen Rulman titreşim işaretleri birbirinden ayrıştırılmıştır. Deney 2 (Veri seti 2) için farklı arıza türlerine sahip rulmanlardan elde edilen titreşim işaretleri ile arıza türleri birbirinden ayrıştırılmıştır. Son deney (Veri seti 3) için ise aynı hızda ve yerde farklı boyutlarda olan arızalar birbirinden ayrıştırılmıştır. Arıza boyutu tespiti gerçekleştirilmiştir. Tüm deneyler için rulman titreşim işaretlerinden öznetelik çıkarımı için 18 farklı entropi bilgisi kullanılmıştır. Elde edilen entropiler ELM modeline giriş olarak kullanılmıştır. ELM, giriş ağırlıkları ve eşit değerleri rastgele oluşturulan ancak çıkış ağırlıkları matematiksel olarak hesaplanan tek gizli katmanlı ileri beslemeli bir yapay sinir ağı (Artificial Neural Network, ANN) modelidir. ELM modelinde değişkenler aşağıdaki denkleme göre normalize edildikten sonra modellere sunularak öğrenme süreci gerçekleştirilir.

$$X_{normalized} = \frac{X_{actual} - X_{min}}{X_{max} - X_{min}} \quad (4.1)$$

ELM'nin başarısı nöronlarda kullanılan aktivasyon fonksiyonuna ve gizli katmandaki nöron sayısı gibi parametrelere bağlıdır. Bu parametreler deneme yanılma ile hatanın kontrol edilmesi ile belirlenmiştir. Bu yüzden bu ELM için sigmoid, tanjant-sigmoid, radyal taban, üçgensel, set sınır, sinüs gibi fonksiyonlar hem eğitim hem de test sürecinde kullanıldı. Gizli katmandaki nöron sayısı da 1-100 arasında eğitim sürecinin başarısı gözlenerek denemeler gerçekleştirilmiştir. ELM için kullanıla parametreler Tablo 4.1.'de verilmiştir.

Tablo 4. 1. ELM modeli parametreler

Mimari	Değerler
Katman sayısı	Giriş katmanı, Gizli katman ve çıkış katmanı
Aktivasyon fonksiyonları	Tanjant sigmoid, sigmoid, radyal taban, üçgensel, sinüs, sert sınır
Nöron sayısı	Giriş katmanı: 18 Gizli katman: 1-100 Çıkış katmanı:1
Öğrenme algoritması	Tek gizli katmanlı ileri beslemeli sinir ağları (SLFNs) için aşırı öğrenme makinesi (ELM)

Sınıflandırma işlemleri farklı eğitim-test oranları için gerçekleştirilmiştir. Elde edilen başarı oranları Tablo 4.2.'de verilmiştir.

Tablo 4. 2. Başarı Oranları

Eğitim Test Oranı	Veri seti1	Veri seti2	Veri seti3
%50-50	99.67	99.58	99.89
%60-40	99.48	99.60	99.86
%70-30	99.89	99.82	100
%80-20	100	100	100

Tablo 4.2.'yebakıldığında tüm eğitim-test oranları için yüksek başarılar gözlenmiştir. Veri seti1 için en yüksek başarı oranı %100 ve en düşük başarı oranı ise %99.48 olarak gözlenmiştir. Veri seti2 için en yüksek başarı oranı %100 ve en düşük başarı oranı ise 99.58 olarak gözlenmiştir. Son veri seti Veri seti3 için ise başarı oranı %99.86-100 arasında değişim göstermiştir. Sonuç olarak kabul edilebilir yüksek başarı oranları gözlenmiştir.

3 deney için gerçekleştirilen denemelere ait diğer performans ölçütleri Tablo 4.3.'te verilmiştir. Bu tablodaki sonuçlar %50-50 eğitim-test oranları için elde edilen sonuçlardır.

Tablo 4. 3. Performans Ölçütleri

Veri Seti	Kesinlik	Duyarlılık	F-Ölçütü
Veri seti1	99.67	99.69	99.78
Veri seti2	99.58	99.62	99.65
Veri seti3	99.89	99.91	99.94

Rulman titreşim işaretlerinden birbirinden farklı 18 adet entropi öznitelik elde edilmiştir. Her deney için her entropi özniteliğinin etkinliğini tespit etmek için denemeler her entropi için ayrı ayrı gerçekleştirilmiştir. Her entropi için elde edilen başarı oranları


Tablo 4.4.'te verilmiştir. Bunun yanında her entropiye ait başarı oranı radar grafik Şekil 4.1.'de verilmiştir.

Tablo 4. 4. Her entropiye ait başarı oranı

Entropy Type	Veri seti1	Veri seti2	Veri seti3
ApEn	89.66	88.22	94.79
SampEn	90.25	86.66	94.58
FuzzyEn	94.23	93.67	97.60
K2En	84.58	69.37	89.06
PermEn	19.33	25.27	24.70
DispEn	82.66	68.02	84.14
CondEn	83.33	80.41	80.41
SpecEn	61.34	59.06	59.58
DistEn	61.08	63.22	55.93
SyDyEn	61.35	61.97	55.10
IncrEn	46.34	39.79	58.85
CosiEn	83.45	88.64	76.45
PhasEn	72.23	71.04	71.45
SlopEn	92.13	88.64	99.85
GridEn	60.41	58.22	56.77
BubbEn	69.33	69.68	61.45
EnofEn	61.45	51.66	51.87
AttnEn	79.67	81.25	79.27

Tablo 4.4.'e bakıldığında Veri seti 1 için en yüksek başarı oranı %94.23 olarak FuzzyEn entropi özneliliği ile gözlenmiştir. En düşük başarı ise %19.33 olarak PermEn entropi ile elde edilmiştir. ApEn, SampEn, FuzzyEn, K2En, DispEn, CondEn, CosiEn gibi 7 her bir entropi özneliliği ile %80 üzerinde başarı gözlenmiştir.

Veri seti 2 için ise en yüksek başarı oranı %93.67 olarak FuzzyEn entropi özneliliği ile elde edilmiştir. En düşük oran ise PermEn entropi ile gözlenmiştir. Son veri seti Veri seti 3 için ise en yüksek başarı oranı SlopeEn entropi özneliliği ile %99.85 gibi yüksek başarı oranı elde edilmiştir. Başarı oranları Şekil 4.1.'in üzerinde de görselleştirilmiştir.



Şekil 4. 1. Her bir entropiye ait başarı oranlarına ait radar grafik

Bu çalışmada gerçekleştirilen 3 deney için ELM'nin parametrelerinin etkileri de gözlenmiştir. ELM'nin gizli katmanında kullanılan nöron sayısının etkileri öncelikle incelenmiştir. Gizli katmanda 10-100 arasında nöron sayısı kullanılarak denemeler gerçekleştirilmiştir. Gizli katmandaki nöron sayısına göre elde edilen başarı oranları Tablo 4.5.'te verilmiştir.

Tablo 4. 5. Nöron sayısına göre başarı oranları

#Nöron	Veri seti1	Veri seti2	Veri seti3
10	95.50	96.25	96.14
20	98.25	99.79	99.68
30	98.80	100	100
40	99.23	99.89	100
50	99.67	99.58	99.89
60	99.89	100	99.89
70	99.79	100	99.79
80	100	99.89	100
90	99.89	100	99.89
100	100	100	99.89

Tablo 4.5.'e bakıldığında gizli katmanda çok az nöron kullanılmasına rağmen kabul edilebilir yüksek başarı oranları elde edilmiştir. Veri seti 1 için başarı oranları %95.50-100 arasında değişim göstermiştir. Veri seti 2 için başarı oranları %96.25-100 ve Veri seti 3 için ise %96.14-100 arasında değişim göstermiştir.

ELM modelinde gizli katmanda farklı aktivasyon fonksiyonları kullanılabilir. Bu çalışmada Triangular basis, sigmoid, Radial basis, Hard Limit ve Sinüs aktivasyon fonksiyonları kullanılmıştır. Her data set için bu aktivasyon fonksiyonları ile elde edilen başarı oranları Tablo 4.6.'da verilmiştir. Başarı oranları %50-50 eğitim-test oranlarına aittir.

Tablo 4. 6. Aktivasyon fonksiyonlarına göre başarı oranları

Aktivasyon Fonksiyonu	Veri seti1 (%)	Veri seti2 (%)	Veri seti3 (%)
Üçgensel taban fonksiyonu	95.67	96.97	90.10
Sigmoid,	99.56	100	100
Radyal taban fonksiyonu	99.89	99.39	99.37
Sert sınır	85.67	87.29	90.31
Sinüs	100	100	99.89

Tablo 4.6.'ya göre en yüksek başarı oranları sinüs aktivasyon fonksiyonları ile elde edilmiştir. En düşük başarı oranları Radial basis aktivasyon fonksiyonu ile gözlenmiştir. Rulman titreşim işaretlerinden elde edilen entropi öznitelikler farklı makine öğrenmesi yöntemler ile de kullanılmıştır. Farklı makine öğrenmesi yöntemlerin etkileri incelenmiştir. Random Forest(RF), Artificial Neural Network (ANN), K-Nearest Neighbour(Knn) ve Support Vector Machine (SVM) ile elde edilen başarı oranları Tablo 4.7.'de verilmiştir.

Tablo 4. 7. Farklı makine öğrenmesi yöntemlere ait başarı oranları

Model	Veri seti1	Veri seti2	Veri seti3
ELM	99.67	99.58	99.89
RF	88.20	98.67	99.23
ANN	88.04	99.10	99.10
Knn	87.79	98.25	99.89
SVM	80.08	99.34	99.89

Tablo 4.7.'ye bakıldığında ELM diğer makine öğrenmesi modellere göre Rulman titreşim işaretlerinin sınıflandırılmasında daha başarılı bulunmuştur.

Oluşturulan rulman deney düzeneğinde kullanılmak üzere lazer ışını ile belirlenen büyüklerde yapay hatalar oluşturulmuştur. Daha sonra bu hatalı rulmanlar belirli hızlarda çalıştırılarak 3 farklı senaryo oluşturulmuştur. Titreşim sinyallerinin yapısını incelemek için 18 farklı entropi yöntemi ile çıkarılan öznitelikleri kullanılmıştır. Daha sonra 3 farklı senaryo için elde edilen bu entropi öznitelikleri kullanılarak ELM modeli ile sınıflandırılmıştır. Aynı zamanda her entropi özniteliği bireysel olarak sınıflandırmada kullanıldığında, Fuzzy entropi yöntemi öznitelikler ile Deney 1 ve Deney 2'de Slope entropi yöntemi özniteliği için Deney 3'te yüksek başarılar elde ettiği gözlemlenmiştir. Sonuç olarak elde edilen deneysel veriler ile entropi özniteliklerinin rulman titreşim sınıflandırılmasında oldukça başarılı sonuçlar verdiği görülmüştür. Bu çalışmada önerilen yaklaşım ile elde edilen başarı oranları literatürdeki farklı yaklaşımlar ile de karşılaştırılmıştır. Bir kısım yaklaşımlar Tablo 4.8.'de verilmiştir. Tablodan görüldüğü gibi önerilen yaklaşım ile kabul edilebilir yüksek sonuçlar gözlenmiştir.

Tablo 4. 8. Rulman arıza veri seti üzerinde diğer yöntemlerle karşılaştırmalı sonuçlar

İsim(ler),(Yıl)	Metot	Veri seti	Arıza tipi	Başarı
Liu ve ark. (2022)	-RCMRDE	-Yazar kurulumu	-Dış bilezik, iç bilezik	-%97.33
Maan Singh Rathore & S. P. Harsha (2022)	-1DCNN	-Yazar kurulumu	-Dış bilezik, iç bilezik	-%98.23
Min Huang ve ark. (2023)	- LMMD	- Paderborn rulman veri seti	-Dış bilezik, iç bilezik	-%95
Farzin Piltan ve Jong-Myon Kim (2023)	- hybrid fuzzy V-structure	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.75- %98
Wu ve ark. (2023)	-NKH-KELM and VMD-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%99
Jaafar K Alsalaet ve ark. (2023)	- CNN and 2D map	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.16- %98.56- %100
Bu çalışmada	-Entropy Variants+ELM	- Kurulum	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	%98.48-100

4.2. Rulman Arızalarının Tespiti İçin 1D-LBP ile Hibrit Derin Öğrenme Tabanlı Yaklaşım

Bu çalışmada rulman titreşim işaretlerinden arıza tespiti için 2 farklı veri seti için denemeler gerçekleştirilmiştir. Veri seti 1 için farklı arıza türlerine sahip rulmanlardan elde edilen titreşim işaretleri ile arıza türleri birbirinden ayrıştırılmıştır. İkinci veri setinde için ise aynı hızda ve yerde farklı boyutlarda olan arızalar birbirinden ayrıştırılmıştır. Arıza boyutu tespiti gerçekleştirilmiştir. Titreşim işaretlerinden rulman arıza tespiti için yeni bir yaklaşım önerilmiştir. Öncelikle rulman titreşim işaretlerine MM-1D-LBP yöntemi uygulanmıştır. Bu yöntem ile titreşim işaretlerinden öznitelik matrisleri elde edilmiştir. MM-1D-LBP yöntemi bir sinyale uygulandığından 5 farklı öznitelik vektörü oluşturulmaktadır. MM-1D-LBP, titreşim sinyallerdeki yerel değişimleri algılayan buna göre dönüşüm uygulayıp etkin özniteliklerin elde edilmesini sağlamaktadır. MM-1D-LBP ile elde edilen öznitelik matrisleri 1D-CNN ve LSTM derin öğrenme modelleri kullanılarak oluşturulan hibrit bir modele giriş olarak verilmiştir. 1D-CNN ve LSTM aynı hiperparametre değerleri ile eğitilmiştir. Parametreler, önerilen hibrit model için en yüksek doğruluğu elde etmek üzere optimize edilmiştir. Bu çalışmada, en iyi sınıflandırma sonuçlarının elde edilmesi için hibrit 1D-CNN-LSTM modeline en uygun batch boyutu değeri 127 olarak belirlenmiştir. Optimizer yöntemi “adam” seçilmişken, MaxEpoch parametre değeri 30 olarak belirlenmiştir. Hibrit MM-1D-LBP+1D-CNN+LSTM ile iki veri seti için yapılan denemeler farklı eğitim-test oranları ile gerçekleştirilmiştir. İki veri seti için elde edilen sonuçlar Tablo 4.9.’da verilmiştir.

Tablo 4. 9. Farklı eğitim-test oranları için MM-1D-LBP+1D-CNN+LSTM ile edilen başarı oranları

Eğitim -Test oranları (%)	Veri seti1		Veri seti2	
	Eğitim	Test	Eğitim	Test
%50-50	96.56	96.15	99.79	99.69
%60-40	99.65	99.22	99.83	99.22
%70-30	99.93	99.31	99.48	99.65


Tablo 4.9.’e bakıldığında en yüksek başarı oranları %70-30 eğitim-test oranları için elde edilmiştir. Veri seti1 ile eğitim seti için %99.93 ve test seti için %99.31 başarı elde edilmiştir. Veri seti2 için ise eğitim seti için %99.48, test seti için ise %99.65 olarak

gözlenmiştir. Eğitim seti oranı arttıkça başarı oranının yükseldiği görülmektedir. İki veri seti için diğer performans ölçütleri Tablo 4.10.'da verilmiştir.

Tablo 4. 10. MM-1D-LBP +1D-CNN+LSTM ile performans ölçütleri

Veri seti	Doğruluk	Kesinlik	Duyarlılık	F-Ölçütü
Veri seti1	0.9931	0.9940	0.9924	0.9924
Veri seti2	0.9965	0.9948	0.9948	0.9948

İki veri seti için elde edilen karışıklık matrisleri ve performans grafikleri Şekil 4.2. ve Şekil 4.3'de verilmiştir. Karışıklık matrisine bakıldığında Veri seti 1 için eğitim verisi için bir titreşim sinyal örneği yanlış sınıflandırılmıştır. Test setinde ise toplam 4 titreşim örneği yanlış sınıflandırılmıştır. İkinci veri seti ile ise eğitim seti için 3 örnek, test seti için 2 titreşim örneği yanlış sınıflandırılmıştır. Performans grafiklerine bakıldığında öğrenme sürecinin stabil olduğu ve test sürecinin başarılı bir şekilde gerçekleştiği görülmektedir.



Şekil 4. 2. 1D-CNN +LSTM hibrit modelin iki veri seti için karışıklık matrisleri



Şekil 4. 3. 1D-CNN+LSTM hibrit modelin performans ve kayıp grafikleri

MM-1D-LBP ile elde edilen öznitelik matrisleri 1D-CNN ve LSTM tabanlı hibrit bir model giriş olarak verilerek rulman titreşim sinyalleri sınıflandırılmıştır. Önerilen 1D-CNN+LSTM hibrit modelin performansını doğrulamak için titreşim sinyallerinden MM-1D-LBP ile elde edilen öznitelik matrisleri LSTM, 1D-CNN ve GRU (Gated Recurrent Units) ile ayrı ayrı birbirinden bağımsız olarak kullanılmıştır. Derin öğrenme metotları ile ayrı ayrı elde edilen başarı oranları Tablo 4.11.'de verilmiştir.

Tablo 4. 11. LSTM, GRU, 1D-CNN ve önerilen metodun başarı değerleri

Model	Veri seti1				Veri seti2			
	Doğ.	Kes.	Duy.	F-Ölç.	Doğ.	Kes.	Duy.	F-Ölç.
LSTM	84.67	0.923	0.901	0.845	97.57	0.977	0.976	0.976
1D-CNN	95.75	0.915	0.925	0.914	99.09	0.980	0.979	0.980
GRU	93.32	0.908	0.866	0.858	95.23	0.921	0.905	0.903
Önerilen Yöntem	99.31	0.994	0.992	0.992	99.65	0.995	0.995	0.995

Tablo 4.11.'e bakıldığında en yüksek başarı oranları önerilen 1D-CNN+LSTM modeli ile gözlenmiştir. İki veri seti içinde önerilen yaklaşım GRU, LSTM ve 1D-CNN modellerin direk kullanmasından daha başarılı bulunmuştur. 1D-CNN modeli önerilen

yaklaşımından sonra en iyi model olarak gözlenmiştir. Titreşim işaretlerin sınıflandırılmasında en başarısız model LSTM olarak elde edilmiştir.

Oluşturulan rulman deney düzeneğinde, lazer ışınıyla belirlenen büyük ölçekli yapay hatalar oluşturulmuş ve iki farklı senaryo için titreşim sinyalleri elde edilmiştir. İki farklı senaryo için titreşim sinyallerinden etkin özniteliklerin çıkarılması için MM-1D-LBP yöntemi önerilmiştir. Daha sonra çıkarılan öznitelik matrisleri kullanılarak 1D-CNN ve LSTM tabanlı hibrit bir derin öğrenme ağı ile rulman arıza türü tahmini gerçekleştirilmiştir. İki farklı veri seti üzerinde gerçekleştirilen denemelerde sırası ile %99.31 ve %99.65 başarı oranları tespit edilmiştir. Titreşim işaretlerinden rulman arıza ve boyutu tahmini için önerilen derin hibrit model 1D-CNN ve LSTM tabanlıdır. Önerilen yaklaşım LSTM, GRU ve 1D-CNN ile karşılaştırılmıştır. Önerilen yaklaşım ile tüm senaryolarda diğer modellerden da yüksek başarılar gözlenmiştir. Bu çalışmada önerilen yaklaşım ile elde edilen başarı oranları literatürdeki farklı yaklaşımlar ile de karşılaştırılmıştır. Bir kısım yaklaşımlar Tablo 4.12.'de verilmiştir. Tablodan görüldüğü gibi önerilen yaklaşım ile kabul edilebilir yüksek sonuçlar gözlenmiştir.

Tablo 4. 12. Rulman arıza teşhisinde diğer yöntemlerle karşılaştırmalı sonuçlar.

İsim(ler), (Yıl)	Metot	Veri seti	Arıza Tipi	Başarı
Hoang and Kang (2019)	-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%99.74
Yoo ve ark. (2023)	-Resnet 50	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%99.97
Deveci ve ark. (2021)	- GoogleNet	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%97.60
Piltan, and Kim (2023)	- hybrid fuzzy V-structure	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.75- -%98
Wu ve ark. (2023)	-NKH-KELM and VMD-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%99
Alonso-González ve ark. (2023)	-Fine KNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%100
Jaafar K Alsalaet ve ark. (2023)	- CNN and 2D map	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.16- -%98.56- -%100
Bu çalışmada	-MM-1D-LBP+1D-CNN-LSTM	- Kurulum	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	%99.31- -%99.65

4.3 LSTM ile 1D-TP Desenler Kullanılarak Rulmanların Kalan Faydalı Ömrünün Tahmini İçin Yeni Bir Yaklaşım

Rulmanlar, zorlu çalışma koşulları ve sürekli aşırı yük altında kolayca hasar gören dönen makinelerin önemli bileşenleridir. Ayrıca rulmanların bozulması, dönen makinelerin performansını doğrudan etkiler. Bu nedenle, rulmanların sağlık durumunun dikkatli bir şekilde izlenmesi ve mekanik sistemlerin güvenilir şekilde çalışmasını sağlarken planlanmamış maliyetin düşürülmesi için hangi önleyici ve temel bakımın gerçekleştirilebileceğine dayanan etkili bir bakım stratejisinin oluşturulması önemlidir.

Bu çalışmada RUL için yeni bir yaklaşım önerilmiştir. Kalan faydalı ömrün doğru tahmini, rulmanların çalıştırılması, bakımı ve planlanmamış problemlerin önlenmesi için önemlidir. Öncelikli olarak rulman titreşim işaretlerinden TP elde edilmiştir. Bu örüntüler

kullanılarak LSTM ile kalan kullanışlı rulman ömrü tahmin edilmiştir. TP ile Alt ve Üst şeklinde iki farklı örüntü vektörü elde edilmektedir. Alt ve Üst vektörlerinde 256 adet örüntü bulunmaktadır. Regresyon için kullanılan LSTM ağına ait hiper parametreler Tablo 4.13.'de verilmiştir.

Tablo 4. 13. LSTM ağı hiper parametreler

Parametreler	Değer
Katmanlar	Dizi girişi LSTM (100) Tam bağlantılı Regresyon katmanı
Girdi boyutu	256
Gizli katman boyutu	100
Çıkış katmanı boyutu	1
Yığın boyutu / Maksimum epoch sayısı	50 / 300
Optimizasyon algoritması	Adam
Öğrenme hızı	0.01

Tablo 4.13.'de verilen parametreler, her bir derin öğrenme modeli için en yüksek doğruluğu elde etmek üzere optimize edilmiştir. Bu çalışmada, en iyi sınıflandırma sonuçlarının elde edilmesi için LSTM en uygun batch boyutu değeri 50 olarak belirlenmiştir. LSTM modeli için optimizasyon yöntemi “adam”, MaxEpoch parametre değeri 300 olarak belirlenmiştir. Önerile yaklaşımı test etmek için 5 farklı performans metriği kullanılmıştır. RMSE, MAE ve SMAPE metriklerin değerlerinin küçük olması beklenirken, RA ve Score metriklerinin değerlerinin yüksek olması beklenmektedir. Tablo 3.7.'de belirtilen eğitim ve test rulman bilgilerine göre 11 farklı senaryo için denemeler gerçekleştirilmiştir. Denemeler 1D-TP yönteminin β parametresinin $\beta = 0.5 \times RMS$ için gerçekleştirilmiştir. 1D-TP örüntülerin Üst örüntüleri için elde edilen performans değerleri Tablo 4.14.'de alt örüntüler için gözlenen performans değerleri Tablo 4.15.'te verilmiştir.

Tablo 4. 14. Üst örüntüler için elde edilen performans değerleri


Senaryolar	Üst örüntüler				
	RMSE	MAE	SMAPE	Score	RA
Senaryo 1	0.2183	0.1603	0.1364	0.4856	0.89
Senaryo 2	0.2293	0.1821	0.1923	0.4621	0.85
Senaryo 3	0.2339	0.1718	0.1476	0.4768	0.8823
Senaryo 4	0.1396	0.1082	0.1185	0.5582	0.8815
Senaryo 5	0.1618	0.1254	0.1115	0.4331	0.9123
Senaryo 6	0.1892	0.1772	0.2047	0.4707	0.8869
Senaryo 7	0.3772	0.2408	0.2026	0.4461	0.8680
Senaryo 8	0.2463	0.2036	0.1810	0.4417	0.8623
Senaryo 9	0.2328	0.1830	0.1817	0.4517	0.8534
Senaryo 10	0.2194	0.2111	0.2167	0.3921	0.8629
Senaryo 11	0.0470	0.0311	0.2300	0.6360	0.9782
Ortalama	0.2074	0.1607	0.1707	0.4824	0.8878

Tablo 4. 15. Alt örüntüler için elde edilen performans değerleri


Senaryolar	Alt örüntüler				
	RMSE	MAE	SMAPE	Score	RA
Senaryo 1	0.1555	0.1400	0.1920	0.4549	0.8254
Senaryo 2	0.0631	0.0547	0.0746	0.5879	0.9257
Senaryo 3	0.3937	0.2491	0.2150	0.5053	0.8757
Senaryo 4	0.3449	0.2215	0.1914	0.5032	0.8757
Senaryo 5	0.1251	0.0893	0.0871	0.3857	0.9165
Senaryo 6	0.3723	0.2441	0.2089	0.4122	0.8604
Senaryo 7	0.4021	0.2590	0.2207	0.4096	0.8564
Senaryo 8	0.3161	0.2160	0.1907	0.4287	0.8656
Senaryo 9	0.2197	0.157	0.1367	0.5050	0.8917
Senaryo 10	0.2214	0.2145	0.2213	0.3945	0.8612
Senaryo 11	0.1817	0.1430	0.1408	0.4032	0.8707
Ortalama	0.2541	0.1807	0.1708	0.4536	0.8750

Tablo 4.14.'e bakıldığında Tüm senaryolar için kabul edilebilir sonuçlar gözlenmiştir. Bearing1_3 için Score değeri=0.4856, RA=0.89, RMSE=0.2183, MAE=0.1603 ve SMAPE=0.1364 olarak elde edilmiştir. Bearing 2_3 için ise Score değeri=0.4707, RA=0.8869, RMSE=0.1892, MAE=0.1772ve SMAPE=0.2047 olarak gözlenmiştir. Son rulman grubundan olan Bearing3_3 için ise Score değeri=0.6360, RA=0.9782, RMSE=0.0470, MAE=0.0311ve SMAPE=0.2300 gibi yüksek performans değerleri gözlenmiştir. Literatürde önerilen yaklaşımların performanslarını karşılaştırmak için bu rulman grupları için elde edilen ortalama değerler kullanılmaktadır. TP yönteminin Up öznitelikleri ile elde edilen ortalama başarı değerleri Score değeri=0,4824, RA=0,8878, RMSE=0.2074, MAE=0,1607 ve SMAPE=0,1707 olarak elde edildiği görülmektedir.


Benzer şekilde Tablo 4.15.'e bakıldığında önemli bir başarı elde edildiği görülmektedir. Ancak 1D-TPLow+LSTM ile gözlenen başarılar 1D-TPUp+LSTM ile elde edilen başarılarla göre düşük kalmıştır. Bearing1_3 için Score değeri=0.4549, RA=0.8254, RMSE=0.1555, MAE=0.1400ve SMAPE=0.1920 olarak elde edilmiştir. Bearing 2_3 için ise Score değeri=0.4122, RA=0.8604, RMSE=0.3723, MAE=0.2441ve SMAPE=0.2089 olarak gözlenmiştir. Son rulman grubundan olan Bearing3_3 için ise Score değeri=0.4032, RA=0.8707, RMSE=0.1817, MAE=0.1430 ve SMAPE=0.1408 gibi yüksek performans değerleri gözlenmiştir. 1D-TPLow+LSTM ile elde edilen ortalama performans değerleri ise Score değeri=0,453, RA=0,875, RMSE=0,254, MAE=0.180 SMAPE=0.170 olarak elde edilmiştir. Hem 1D-TPUp hem de 1D-TPLow öznetelikler ile diğer rulmanlar için de RUL tahmin edilmesinde önemli sonuçlar gözlenmiştir. Denemeleri gerçekleştirilen 11 test Rulmandan Bearing1_3, Bearing 2_3 ve Bearing3_3 için elde edilen uyum, hata ve data dağılım grafikleri Şekil 4.4., 4.5. ve 4.6.'da gösterilmektedir. RUL için tahmin değerleri 30 uzunlukta belirlenen bir pencere boyutuna göre hareketli ortalamaları alınarak yumuşatılmıştır. Grafikler 1D-TPUp+LSTM ile elde edilen grafiklerdir. Uyum grafiklerine bakıldığında RUL için hedef değerler ile tahmin edilen değerler arasında bir uyum olduğu görülmektedir.



Şekil 4. 4. Bearing1_3 için uyum ve hata grafikleri




Şekil 4. 5. Bearing2_3 için uyum ve hata grafikleri



Şekil 4. 6. Bearing3_3 için uyum ve hata grafikleri

Skore metriği hesaplanırken tahmin edilen değerin gerçek değerden büyük veya küçük olma durumları aynı şekilde değerlendirilmemektedir. Tahmin edilen değerlerin gerçek değerlerden küçük olması hata olarak belirtilir ancak mekanik sistemin gözden geçirilmesi önemli olacaktır. Ancak tahmin değerlerin gerçek değerlerden büyük tahmin edilmesi hatalı kararların alınmasına neden olabilir. Bu durum ciddi mekanik sorunlara

da sebebiyet verebilir. Bearing1_3, Bearing_2_3 ve Bearing_3_3 için β parametresinin $\beta = 0.5xRMS$ olması durumunda elde edilen Score değerlere ait grafikler Şekil 4.7.'de gösterilmiştir.



Şekil 4. 7. Bearing1_3, Bearing2_3 ve Bearing3_3 için Score grafikler

1D-TP yönteminin β denilen önemli bir parametresi bulunmaktadır. Bu parametrenin farklı değerlerine göre farklı örüntüler elde edilmektedir. Bu parametre sinyal bir filtre olarak kullanılmaktadır. Bu parametrenin etkisini incelemek için β 'nin farklı değerleri ile Bearing1_3, Bearing2_3 ve Bearing3_3 titreşim işaretleri denemeler gerçekleştirilmiştir. $\beta = \{0.5xRMS, 1xRMS, 1.5xRMS, 2xRMS, 2.5xRMS \text{ ve } 3xRMS\}$ için tahminler yapılmıştır. β Parametresinin farklı değerleri ile elde edilen öznelilikler kullanılarak LSTM ile gözlenen RMSE ve Score değerler Tablo 4.16.'de verilmiştir. β değerlerine göre performansı en iyi olan öznelilik gruplarına ait sonuçlar bold olarak gösterilmiştir.

Tablo 4. 16. β parametresinin farklı değerlerine göre elde edilen başarı oranları

Beta	Üst örüntüler						Alt örüntüler					
	Bearing 1_3		Bearing 2_3		Bearing 3_3		Bearing 1_3		Bearing 2_3		Bearing 3_3	
	RM SE	Score	RM SE	Score	RM SE	Score	RM SE	Score	RM SE	Score	RM SE	Score
0.5xRMS	0.2183	0.4856	0.1892	0.4707	0.0470	0.6360	0.1949	0.4549	0.3723	0.4322	0.1817	0.4032
1.0xRMS	0.2832	0.5173	0.0854	0.4747	0.1150	0.5827	0.1781	0.4336	0.3396	0.4357	0.1292	0.5124
1.5xRMS	0.1355	0.4313	0.3253	0.3462	0.2623	0.3660	0.1629	0.4484	0.3700	0.3750	0.3246	0.2934
2.0xRMS	0.0798	0.5584	0.3740	0.3539	0.3702	0.3645	0.1295	0.4843	0.3493	0.3890	0.3212	0.3123
2.5xRMS	0.1490	0.5346	0.3122	0.3607	0.3288	0.2768	0.1494	0.4979	0.4010	0.3586	0.2479	0.3982
3.0xRMS	0.1930	0.4463	0.3402	0.3205	0.3445	0.2634	0.2888	0.4052	0.3723	0.4374	0.2342	0.3446

Tablo 4.16.'e bakıldığında Üst öznitelikler kullanılarak Bearing1_3 için en yüksek başarı $\beta = 2xRMS$ olması durumunda elde edilmiştir. RMSE=0.0798 ve Score=0.5584 olarak gözlenmiştir. Bearing2_3 için $\beta = 1xRMS$ ile RMSE=0.0854 ve Score=0.4747 olarak elde edilmiştir. Son olarak Bearing3_3 için en yüksek başarı $\beta = 0.5xRMS$ ile RMSE=0.0470 ve Score=0.6360 olarak gözlenmiştir. Alt öznitelikler ile elde edilen başarıları bakıldığında Bearing1_3 için en yüksek başarı $\beta = 2.5xRMS$ ile RMSE=0.1494 ve Score=0.4979 olarak gözlenmiştir. Bearing2_3 için ise en yüksek başarı $\beta = 3xRMS$ için RMSE=0.3723 ve Score=0.4374 olarak elde edilmiştir. Son olarak Bearing3_3 için en yüksek başarı $\beta = 0.5xRMS$ ile RMSE=0.1817 ve Score=0.4032 olarak gözlemiştir. Sonuçlara bakıldığında Üst öznitelikler ile gözlenen başarıların Alt özniteliklere göre daha yüksek olduğu görülmektedir. Bunun yanında β parametresinin hangi değeri ile en iyi sonucun elde edildiği denemeler sonucunda karar verilmelidir. Tabloya bakıldığında Rulmana göre ve titreşim sinyallerine göre farklı β değerlerine göre farklı başarıların gözlendiği görülmüştür. β parametresinin farklı değerlerine göre Üst ve Alt öznitelikler ile gözlenen RMSE ve Score değerlerin grafik üzerindeki dağılımı Şekil 14'te verilmiştir. Şekilden de anlaşıldığı gibi genel olarak $\beta = 0.5xRMS$ ile daha küçük RMSE ve büyük Score değerlerin elde edildiği görülmektedir.



Şekil 4. 8. β parametresinin farklı değerleri için RMSE ve Score değerleri

Önerilen yaklaşım ile Bearing1_3 ve Bearing3_3 için herhangi bir zamanda hesaplanan ömür değeri ile tahmin edilen değerlerin karşılaştırılması rastgele zamanlar için elde edilen değerler Tablo 4.17.'de verilmiştir. Tablo 4.17.'te ayrıca seçilen rastgele zamanlar için tahmini RUL değeri ile gerçek RUL değeri arasındaki hata ölçüsü olan RA değerleri verilmiştir. Elde edilen değerlere göre Bearing1_3 ve Bearing3_3 için kabul edilebilir tahminler elde edilmiştir.

Tablo 4. 17. Rulman1_3 ve Rulman3_3 için tahmini ve hesaplanan RUL

Bearing1_3				Bearing3_3			
Çalışma süresi (s)	Hesaplanan RUL (s)	Tahmin edilen RUL (s)	RA	Çalışma süresi (s)	Hesaplanan RUL (s)	Tahmin edilen RUL (s)	RA
1000	1.00	0.9604	0.9604	500	1.00	1.02	0.9800
10000	0.8912	0.9791	0.9013	1000	1.00	0.9896	0.9896
15500	0.2808	0.2991	0.9348	1300	1.00	0.9877	0.9877
16000	0.2253	0.2283	0.9866	1600	1.00	0.9699	0.9699
16500	0.1698	0.1558	0.9175	2000	0.8693	0.9215	0.9399
17000	0.1143	0.0992	0.8678	2500	0.5852	0.5487	0.9376
17500	0.0588	0.0620	0.9455	3000	0.2955	0.4422	0.5035
18000	0.0033	0.0050	0.4848	3500	0.0170	0.170	0.4567

1D-TP+LSTM ile önerilen yaklaşımın başarısını daha iyi anlamak için elde edilen sonuçların literatürde aynı PRONOSTIA platformundan alınan veri seti ile yapılan çalışmalar ile karşılaştırılmıştır. RMSE ve MAE ölçütleri için elde edilen ortalama

sonuçlar ve literatürdeki diğer sonuçlar Tablo 4.18.'de verilmiştir. Tablodan görüldüğü gibi aynı veri setleri üzerinde farklı metotların uygulandığı görülmektedir. Bu çalışmada önerilen 1D-TP+LSTM ile daha iyi sonuçların elde edildiği görülmüştür.

Tablo 4. 18. Önerilen yönteme ait performans değerlerin literatürdeki çalışmalar ile karşılaştırılması

Literatür	Metot	MAE	RMSE
Urbanowicz vd, 2018	Relief-SVM	0.21	0.2500
Huang vd,2019	Bi-LSTM	0.19	0.2300
Li vd, 2019	MS-CNN	19.66	23.62
Li vd, 2019	DNN	29.34	34.56
Li vd, 2019	SSL	22.48	25.87
Li vd, 2019	SSH	21.89	25.92
Malekipirbazari vd, 2021	PCA-SVM	0.52	0.5900
Huang vd, 2021	DCNN	0.45	0.4900
Bu çalışmada	1D-TP+LSTM	0.1607	0.2074

5. SONUÇLAR VE ÖNERİLER

5.1. Rulman Arızalarına Yönelik Sonuç ve Öneriler

5.1.1. Aşırı makine öğrenmesi ile entropi varyantlarını kullanarak rulman arıza teşhisi

- Bu çalışma, endüstriyel makinelerin en kritik bileşenlerinden biri olan rulmanların arıza teşhis ve tahmin süreçlerine yönelik yenilikçi bir yaklaşım sunmaktadır.
- Rulmanlar, makinelerdeki döner hareketi destekleyen temel parçalar olup, arızalarının önceden tespiti, endüstriyel süreçlerin kesintisiz ve verimli bir şekilde işlemesi açısından hayati önem taşımaktadır. Arızalı bir rulmanın sistemin genel performansını ciddi şekilde etkileyebileceği göz önünde bulundurulduğunda, bu alandaki teşhis ve tahmin çalışmalarının önemi bir kat daha artmaktadır.
- Bu çalışma kapsamında, rulman arızalarının erken teşhisine yönelik olarak lazer ışını kullanılarak yapay hatalar oluşturulmuş ve bu hatalar, farklı hızlarda çalıştırılarak titreşim sinyalleri üzerinden kapsamlı bir şekilde analiz edilmiştir. Bu sayede, arızaların farklı hız ve yük koşullarında rulmanların titreşim profillerine nasıl yansıdığı ortaya koyulmuştur.
- Rulman arızalarının teşhisi için öznitelik çıkarımı sürecinde, entropi temelli 18 farklı yöntem kullanılarak öznitelikler elde edilmiştir.
- Bu öznitelikler arasında, rulman arızalarının farklı çalışma koşulları altında doğru bir şekilde sınıflandırılmasını sağlayacak yüksek bilgi içeriğine sahip olanlar seçilmiştir. Elde edilen öznitelikler, üç farklı deney senaryosu altında Entropi Tabanlı ELM (Ekstrem Öğrenme Makinesi) modeli ile analiz edilmiştir. Özellikle Fuzzy entropi yöntemi, Deney 1 ve Deney 2 senaryolarında en yüksek başarıyı sağlamıştır. Deney 3'te ise Slope entropi yöntemi diğer yöntemlerden daha üstün bir performans sergilemiştir.
- Bu bulgular, entropi özniteliklerinin farklı çalışma koşullarında elde edilen titreşim sinyallerinin özelliklerini doğru bir şekilde yansıtabildiğini ve arıza sınıflandırmasında oldukça etkili olduğunu göstermektedir. Çalışmanın başarısı, %98.48 ile %100 arasında değişen yüksek doğruluk oranları ile kendini göstermektedir.

Tablo 5. 1. Rulman arızası veri seti üzerinde diğer yöntemlerle karşılaştırmalı sonuçlar

İsim(ler), (Yıl)	Metot	Veri seti	Arıza Tipi	Başarı
Liu ve ark. (2022)	-RCMRDE	-Yazar kurulumu	-Dış bilezik, iç bilezik	-%97.33
Maan Singh Rathore & S. P. Harsha (2022)	-1DCNN	-Yazar kurulumu	-Dış bilezik, iç bilezik	-%98.23
Min Huang ve ark. (2023)	- LMMD	- Paderborn rulman veri seti	-Dış bilezik, iç bilezik	-%95
Farzin Piltan ve Jong-Myon Kim (2023)	- hybrid fuzzy V-structure	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.75- %98
Wu ve ark. (2023)	-NKH-KELM and VMD-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%99
Jaafar K Alsalaet ve ark. (2023)	- CNN and 2D map	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.16- %98.56- %100
Bu çalışmada	-Entropy Variants+ELM	- Kurulum	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	%98.48- %100

- Çalışmada kullanılan yöntemler, Tablo 5.1.'deki literatürde yer alan diğer modern yaklaşımlarla kıyaslandığında, önerilen yöntemin üstün performansını ortaya koymaktadır. Örneğin, Liu ve arkadaşlarının (2022) RCMRDE yöntemini kullanarak elde ettikleri %97.33 başarı oranı ile Maan Singh Rathore ve S.P. Harsha'nın (2022) 1D-CNN yönteminde elde ettikleri %98.23 başarı oranı, çalışmamızda önerilen yöntemin daha yüksek performans sergilediğini ortaya koymaktadır.
- Ayrıca, Farzin Piltan ve Jong-Myon Kim (2023), hibrit bulanık V-yapı ile %98.75 başarı elde etmişken, Wu ve arkadaşlarının (2023) NKH-KELM ve VMD-CNN kombinasyonu %99 başarı oranına ulaşmıştır.
- Bununla birlikte, önerilen Entropi Tabanlı ELM modeli, %98.48 ile %100 arasında değişen doğruluk oranları sunarak, özellikle arıza teşhisinde öznitelik seçimi ve sınıflandırma doğruluğu açısından literatürdeki diğer yöntemlerden daha üstün sonuçlar ortaya koymaktadır. Bu, ELM modelinin esnek ve hızlı

öğrenme kapasitesine ek olarak entropi tabanlı özniteliklerin yüksek ayırt edicilik gücünü kullanmasının bir sonucudur.

- Çalışmanın sonuçları değerlendirildiğinde, önerilen Entropi Tabanlı ELM modelinin endüstriyel uygulamalarda gerçek zamanlı olarak kullanılabilir bir çözüm sunduğu görülmektedir. Bu çözüm, endüstriyel ortamlarda rulman arızalarının hızlı bir şekilde teşhis edilmesine olanak tanımakta ve dolayısıyla bakım süreçlerini optimize ederek operasyonel maliyetleri azaltmaktadır.
- Ayrıca, lazer ışını ile oluşturulan yapay hatalar sayesinde, rulman arızalarının farklı şiddetlerdeki etkilerinin gözlemlenebilmesi sağlanmış ve modelin bu çeşitlilikteki arızalara karşı nasıl bir performans gösterdiği incelenmiştir. Sonuçlar, önerilen yöntemin arıza teşhisinde güvenilir bir çözüm sunduğunu ve farklı çalışma koşullarına kolayca uyum sağlayabildiğini ortaya koymaktadır.
- Çalışmanın öne çıkan bir diğer önemli yönü, entropi özniteliklerinin her birinin bağımsız olarak sınıflandırma performansına katkıda bulunmasıdır. Özellikle Fuzzy ve Slope entropi yöntemleri ile elde edilen yüksek başarı oranları, bu özniteliklerin arıza teşhisindeki etkinliğini göstermektedir. Örneğin, literatürde kullanılan bazı geleneksel yöntemler, sınırlı sayıda öznitelik kullanarak belirli koşullarda yüksek doğruluk oranları elde etse de, önerilen yöntem farklı koşullarda elde edilen sinyalleri daha başarılı bir şekilde sınıflandırmaktadır. Bu durum, modelin genel anlamda esnek ve güçlü bir yapıya sahip olduğunu göstermektedir.
- Gelecek çalışmalar açısından, önerilen modelin farklı veri setleri ve çalışma koşulları altında test edilmesi, modelin genelleme yeteneği hakkında daha kapsamlı bilgi sunacaktır.
- Ek olarak, farklı entropi yöntemlerinin birlikte kullanılması ve elde edilen özniteliklerin diğer makine öğrenme algoritmaları ile değerlendirilmesi, modelin performansını daha da artırma potansiyeline sahiptir. Özellikle, mevcut yöntemin daha büyük ve karmaşık endüstriyel sistemlerde uygulanması, sistemin genelleme kapasitesinin test edilmesi ve farklı arıza tiplerine karşı gösterdiği performansın değerlendirilmesi açısından önem arz etmektedir.
- Sonuç olarak, önerilen entropi varyantları ve ELM tabanlı model, endüstriyel ortamlarda rulman arızalarının hızlı ve doğru bir şekilde teşhis edilmesine yönelik başarılı bir alternatif çözüm sunmaktadır.

- Çalışmanın bulguları, sadece akademik literatüre değil, aynı zamanda endüstriyel bakım ve onarım stratejilerine de önemli katkılar sağlamaktadır. Geliştirilen bu yenilikçi yaklaşımın endüstriyel süreçlerde daha yaygın bir şekilde kullanılabileceği ve gelecekteki çalışmalarla daha da geliştirilebileceği öngörülmektedir.

5.1.2. Rulman arızalarının tespiti için 1d-lbp ile hibrit derin öğrenme tabanlı yaklaşım

- Diğer bir çalışmada, rulmanların hayati önemi vurgulanarak endüstriyel makinelerin verimliliğini ve güvenilirliğini sağlamak adına farklı bir yöntemle rulman arıza teşhisi üzerinde yoğunlaşmıştır. Rulman arızaları, makine operasyonlarında ciddi aksamalara ve ekonomik kayıplara yol açabileceğinden, araştırmacılar bu alanda sürekli olarak daha doğru ve güvenilir teşhis yöntemleri geliştirmeye çalışmaktadır. Bu bağlamda, çalışmada önerilen yöntem, lazer ışını kullanılarak oluşturulan yapay hatalarla rulman arızalarının boyut ve konumlarını belirlemek üzere tasarlanmıştır.
- Önerilen yöntemde, MM-1D-LBP tekniği ile öznelik çıkarımı yapılarak, 1D-CNN ve LSTM tabanlı hibrit bir derin öğrenme ağı kullanılarak arıza türü tahmini gerçekleştirilmiştir.
- Bu yöntem, literatürde sıklıkla kullanılan GRU, LSTM ve 1D-CNN gibi modellerle karşılaştırıldığında daha üstün bir performans sergilemiştir. Denemelerde iki farklı veri seti kullanılmış olup, bu veri setlerinde sırasıyla %99.31 ve %99.65 oranlarında başarı elde edilmiştir.
- Bu başarı oranları, rulman arıza teşhisinde mevcut literatürdeki diğer çalışmaların ortalama başarı oranlarının üzerindedir. Literatürde, örneğin bir çalışmada GRU tabanlı model ile %95, LSTM tabanlı model ile %97 başarı oranları elde edilirken, önerilen yöntem ile daha yüksek doğruluk değerlerine ulaşılmıştır. Bu durum, önerilen yöntemin arıza teşhisi doğruluğunu artırmada ve genel olarak sınıflandırma hatalarını minimize etmede etkin bir yaklaşım olduğunu göstermektedir.
- Deneysel kurulum, veri toplama ve öznelik çıkarımı aşamalarında lazer ışınıyla oluşturulan yapay hatalarla birlikte farklı titreşim sinyalleri kullanılmıştır. Bu

sayede, rulman arızasının geniş bir spektrumda ele alınması sağlanmış ve yöntemin farklı senaryolara uyarlanabilirliği test edilmiştir.

- Çıkarılan öznitelikler, önerilen hibrit modelin hem geçmiş hem de mevcut durumlara ilişkin öngörülerde bulunabilmesi için optimize edilmiştir.
- Bu hibrit modelin kullanımı, özellikle rulman arıza teşhisinde sıklıkla kullanılan LSTM ve CNN'in avantajlarını birleştirerek, daha yüksek doğruluk oranlarının elde edilmesini sağlamıştır.
- Diğer bir çalışmada, rulmanların hayati önemi vurgulanarak endüstriyel makinelerin verimliliğini ve güvenilirliğini sağlamak adına farklı bir yöntemle rulman arıza teşhisi üzerinde yoğunlaşmıştır. Rulman arızaları, makine operasyonlarında ciddi aksamalara ve ekonomik kayıplara yol açabileceğinden, araştırmacılar bu alanda sürekli olarak daha doğru ve güvenilir teşhis yöntemleri geliştirmeye çalışmaktadır. Bu bağlamda, çalışmada önerilen yöntem, lazer ışını kullanılarak oluşturulan yapay hatalarla rulman arızalarının boyut ve konumlarını belirlemek üzere tasarlanmıştır.
- Önerilen yöntemde, MM-1D-LBP tekniği ile öznitelik çıkarımı yapılarak, 1D-CNN ve LSTM tabanlı hibrit bir derin öğrenme ağı kullanılarak arıza türü tahmini gerçekleştirilmiştir.
- Bu yöntem, literatürde sıklıkla kullanılan GRU, LSTM ve 1D-CNN gibi modellerle karşılaştırıldığında daha üstün bir performans sergilemiştir. Denemelerde iki farklı veri seti kullanılmış olup, bu veri setlerinde sırasıyla %99.31 ve %99.65 oranlarında başarı elde edilmiştir.
- Bu başarı oranları, rulman arıza teşhisinde mevcut literatürdeki diğer çalışmaların ortalama başarı oranlarının üzerindedir. Literatürde, örneğin bir çalışmada GRU tabanlı model ile %95, LSTM tabanlı model ile %97 başarı oranları elde edilirken, önerilen yöntem ile daha yüksek doğruluk değerlerine ulaşılmıştır. Bu durum, önerilen yöntemin arıza teşhisi doğruluğunu artırmada ve genel olarak sınıflandırma hatalarını minimize etmede etkin bir yaklaşım olduğunu göstermektedir.
- Deneysel kurulum, veri toplama ve öznitelik çıkarımı aşamalarında lazer ışınıyla oluşturulan yapay hatalarla birlikte farklı titreşim sinyalleri kullanılmıştır. Bu sayede, rulman arızasının geniş bir spektrumda ele alınması sağlanmış ve yöntemin farklı senaryolara uyarlanabilirliği test edilmiştir.

- Çıkarılan öznitelikler, önerilen hibrit modelin hem geçmiş hem de mevcut durumlara ilişkin öngörülerde bulunabilmesi için optimize edilmiştir.
- Bu hibrit modelin kullanımı, özellikle rulman arıza teşhisinde sıklıkla kullanılan LSTM ve CNN'in avantajlarını birleştirerek, daha yüksek doğruluk oranlarının elde edilmesini sağlamıştır.
- Sonuçlar, önerilen yöntemin Tablo 5.2.'deki literatürde yer alan diğer yöntemlerle karşılaştırıldığında, önemli ölçüde üstünlük sağladığını ortaya koymuştur. Örneğin, bir çalışmada 1D-CNN ile %98.4 doğruluk elde edilirken, MM-1D-LBP ve hibrit CNN-LSTM yaklaşımı ile %99'un üzerindeki başarısı dikkate değerdir.
- Ayrıca, MM-1D-LBP yöntemi sayesinde öznitelik çıkarım sürecinde oluşabilecek bilgi kayıpları minimize edilmiş ve verinin tüm yapısal özelliklerinin korunarak modele entegre edilmesi sağlanmıştır. Bu yöntem ile kullanılan öznitelik çıkarım ve sınıflandırma aşamaları, özellikle karmaşık makine yapılarında arıza teşhis doğruluğunu artırarak endüstriyel uygulamalar için daha güvenilir ve uzun ömürlü makine kullanımını destekleyebilecek potansiyele sahiptir.
- Özetle, önerilen yöntemin yüksek doğruluk oranları, rulman arıza teşhisi alanında gelecekteki çalışmalar için referans niteliğinde olabileceğini göstermektedir.
- Literatürdeki mevcut yöntemlerle kıyaslandığında elde edilen yüksek performans, önerilen yöntemin endüstriyel makinelerde daha geniş bir uygulama alanı bulabileceğini ortaya koymaktadır. Bu çalışma, makine öğrenimi tabanlı teşhis yöntemlerinin gelişimine katkı sağlayarak, özellikle karmaşık çalışma koşullarında ve farklı veri senaryolarında daha sağlam teşhis modelleri geliştirilmesi açısından literatürdeki boşlukları doldurma potansiyeline sahiptir.

Tablo 5. 2. Rulman arıza teşhisinde diğer yöntemlerle karşılaştırmalı sonuçlar.

İsim(ler), (Yıl)	Metot	Veri seti	Arıza Tipi	Başarı
Hoang and Kang (2019)	-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%99.74
Deveci ve ark. (2021)	- GoogleNet	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%97.60
Yoo ve ark. (2023)	-Resnet 50	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-Dış bilezik, iç bilezik	-%99.97
Piltan, and Kim (2023)	- hybrid fuzzy V-structure	-Case Western Reserve Üniversitesi (CWRU) kurulumu	-İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-% 98.75-% 98
Wu ve ark. (2023)	-NKH-KELM and VMD-CNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-% 99
Alonso-González ve ark. (2023)	-Fine KNN	-Case Western Reserve Üniversitesi (CWRU) kurulumu	İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-% 100
Jaafar K Alsalaet ve ark. (2023)	- CNN and 2D map	-Case Western Reserve Üniversitesi (CWRU) kurulumu	İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	-%98.16-% 98.56-% 100
Bu çalışmada	-MM-1D-LBP+1D-CNN-LSTM	- Kurulum	İç bilezik arızası, Dış bilezik arızası, ve Bilye arızası	%99.31-% 99.65

5.2. Rulman Ömür Tahminine Yönelik Sonuç ve Öneriler

- Bu çalışmada önerilen rulman ömrü tahmini yaklaşımı, endüstriyel bakım süreçlerinde rulman arızalarının erken teşhis edilmesine yönelik önemli bir adım atmaktadır. Titreşim sinyalleri üzerinden yapılan tahminler, makinelerin bakım süreçlerini optimize etmeye ve olası arızaların erken fark edilmesine olanak tanımaktadır.
- Bu çalışma kapsamında kullanılan TP (Temsili Örüntüleme) ve LSTM (Uzun Kısa Süreli Bellek) modellerinin birleşimi, rulman ömrü tahmini sürecinde dikkat çekici bir başarı sergilemiştir. Rulmanların arızalanmadan önce kalan kullanım ömrünün tahmin edilmesi, sistemin genel sağlığını koruma açısından kritik bir öneme sahiptir.

- Önerilen yaklaşım, Pronostia platformundan elde edilen veri setleri üzerinde test edilmiştir. Titreşim sinyalleri, farklı hızlarda çalışan rulmanların oluşturduğu örüntüler aracılığıyla incelenmiştir.
- Denemeler sırasında, β parametresine bağlı olarak değişen örüntüler incelenmiş ve 11 farklı senaryoda kapsamlı bir analiz gerçekleştirilmiştir. Elde edilen sonuçlara göre, TP yöntemi ile çıkarılan düşük ve yüksek frekanslı örüntüler (Low ve Up features) rulman ömrü tahmininde belirleyici olmuştur. Özellikle Bearing3_3 senaryosu için elde edilen en düşük hata değeri (RMSE=0.0470) ve en yüksek Score değeri (0.6360) ile yöntemin oldukça başarılı olduğu ortaya koyulmuştur.
- Bu bulgular, yöntemin doğruluğunun yüksek olduğunu ve endüstriyel uygulamalarda güvenilir bir ömür tahmini sağlama potansiyelini taşımaktadır.

Tablo 5.3. Önerilen yönteme ait performans değerlerin literatürdeki çalışmalar ile karşılaştırılması

Literatür	Metot	MAE	RMSE
Urbanowicz vd, 2018	Relief-SVM	0.21	0.2500
Huang vd,2019	Bi-LSTM	0.19	0.2300
Li vd, 2019	MS-CNN	19.66	23.62
Li vd, 2019	DNN	29.34	34.56
Li vd, 2019	SSL	22.48	25.87
Li vd, 2019	SSH	21.89	25.92
Malekipirbazari vd, 2021	PCA-SVM	0.52	0.5900
Huang vd, 2021	DCNN	0.45	0.4900
Bu çalışmada	1D-TP+LSTM	0.1607	0.2074

- Literatürle karşılaştırıldığında, önerilen modelin üstünlüğü daha belirgin hale gelmektedir. Huang vd. (2019) tarafından önerilen Bi-LSTM modeli, 0.2300 RMSE değeri ile önerilen 1D-TP+LSTM modeline kıyasla daha düşük bir doğruluk sergilemektedir.
- Benzer şekilde, Urbanowicz vd. (2018) tarafından kullanılan Relief-SVM modelinin RMSE değeri 0.2500 olarak kaydedilmiştir.

- Çalışmamızda kullanılan modelin 0.2074 RMSE değeri, bu yöntemlere göre daha yüksek bir tahmin doğruluğu sağlamaktadır. Ayrıca, Malekipirbazari vd. (2021) tarafından kullanılan PCA-SVM yönteminin 0.5900 RMSE değeri ve DCNN tabanlı modelin (Huang vd., 2021) 0.4900 RMSE değeri ile kıyaslandığında, önerilen modelin hata oranlarının daha düşük olduğu ve genel olarak daha iyi bir performans sunduğu gözlemlenmiştir.
- Pronostia platformundan elde edilen verilerle yapılan bu analizler, önerilen yöntemin sadece literatürdeki yaklaşımlar karşısında yüksek doğruluk sunmakla kalmayıp, aynı zamanda ömür tahmini için istikrarlı bir çözüm sunduğunu göstermektedir.
- 1D-TP+LSTM modelinin doğruluğunun yüksek olması, onu endüstriyel sistemlerde daha yaygın bir kullanım için uygun hale getirmektedir. Modelin entegre edilmesi ile bakım süreçlerinde maliyetlerin düşürülmesi ve arızaların öngörülmesi açısından daha etkili bir bakım stratejisi geliştirilmesi mümkün olacaktır.
- Bu çalışmanın endüstriyel alandaki katkısı, sadece yüksek tahmin doğruluğu ile sınırlı değildir; aynı zamanda modelin dinamik yapısı, farklı rulman türleri ve çalışma koşullarına uyarlanabilirliğini de artırmaktadır.
- TP yönteminin β parametresi ile çeşitli örüntülerin yakalanması, yöntemin geniş bir uygulama alanına hitap etmesini sağlamaktadır. Bu çeşitlilik, sistemin farklı koşullarda performansını optimize etme potansiyelini artırmaktadır. Ayrıca, kullanılan RA, RMSE, MAE, SMAPE ve Score metrikleri aracılığıyla yöntemin performansını ölçme ve iyileştirme imkanı, yöntemin endüstriyel ortamlarda gerçek zamanlı kullanımını teşvik etmektedir.
- Özellikle Bearing1_3, Bearing2_3 ve Bearing3_3 örnekleri üzerinde gerçekleştirilen denemeler, yöntemin tutarlılığını ve güvenilirliğini ortaya koymaktadır. Bearing1_3 için gözlemlenen RMSE=0.0798 ve Score=0.5584 değerleri, yöntemin başarılı tahminlerde bulunduğunu göstermektedir. Bearing2_3 senaryosunda ise RMSE=0.0854 ve Score=0.4747 olarak tespit edilen değerler, yöntemin doğruluğunun farklı çalışma koşullarında da yüksek olduğunu kanıtlamaktadır. Son olarak, Bearing3_3 için elde edilen en düşük RMSE değeri ve en yüksek Score değeri, önerilen modelin en iyi performansı bu senaryoda sergilediğini ortaya koymaktadır.

- Literatürdeki diğer yöntemler incelendiğinde, önerilen yaklaşımın yüksek doğruluğu ve düşük hata oranlarıyla ön plana çıktığı görülmektedir. Rulman ömrü tahmini için önerilen 1D-TP+LSTM modelinin, yüksek doğruluk ve düşük hata oranlarına sahip diğer yöntemlere kıyasla daha etkili olduğu ve endüstriyel uygulamalarda güvenle kullanılabileceği sonucuna varılmıştır. Çalışmanın sonuçları, bakım süreçlerinde daha etkin ve sürdürülebilir bir sistem geliştirmek adına önemli bir kaynak oluşturmakta ve önerilen yöntemin gelecekteki endüstriyel uygulamalar için güçlü bir aday olduğunu göstermektedir.

5.3. Gelecekte Yapılabilecek Çalışmalar

- Gelecek çalışmalarda rulman arıza teşhisi ve ömür tahmini için yapay zeka tabanlı daha gelişmiş modeller geliştirilebilir.
- Özellikle, çoklu veri kaynaklarının entegrasyonu ve gerçek zamanlı izleme sistemleri sayesinde tahmin doğruluğu artırılabilir.
- Derin öğrenme modellerinin adaptif öğrenme yetenekleri geliştirilerek değişen çalışma koşullarına uyum sağlaması hedeflenebilir.
- Küçük veri sorununu aşmak için veri artırma teknikleri ve sentetik veri üretimi kullanılabilir.
- Ayrıca, enerji verimliliği sağlayan yöntemlerle rulman arıza tahmini süreçleri optimize edilebilir.
- RUL tahmini için yeni performans metrikleri belirlenerek daha güvenilir sonuçlar elde edilebilir.
- Sensör teknolojilerindeki gelişmelerle düşük maliyetli ve yüksek hassasiyetli tahmin sistemleri oluşturulabilir.
- Bu çalışmalar, bakım maliyetlerini azaltarak endüstriyel sistemlerin güvenilirliğini artıracaktır.

KAYNAKLAR

- Ahmad, W., Khan, S. A., Islam, M. M., & Kim, J. M. (2019). A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*, 184, 67-76. <https://doi.org/10.1016/j.ress.2018.02.003>
- Alonso-González, M., Díaz, V. G., Pérez, B. L., G-Bustelo, B. C. P., & Anzola, J. P. (2023). Bearing fault diagnosis with envelope analysis and machine learning approaches using CWRU dataset. *IEEE Access*, 11, 57796-57805. <https://doi.org/10.1109/ACCESS.2023.3283466>
- Alsalaet, J. K., Hajnayeb, A., & Bahedh, A. S. (2023). Bearing fault diagnosis using normalized diagnostic feature-gram and convolutional neural network. *Measurement Science and Technology*, 34(4), 045901. <https://doi.org/10.1088/1361-6501/aca9e9>
- Antoni, J. (2009). Cyclostationarity by examples. *Mechanical Systems and Signal Processing*, 23(4), 987-1036. <https://doi.org/10.1016/j.ymssp.2008.10.010>
- Bai, R., Xu, Q., Meng, Z., Cao, L., Xing, K., & Fan, F. (2021). Rolling bearing fault diagnosis based on multi-channel convolution neural network and multi-scale clipping fusion data augmentation. *Measurement*, 184, 109885. <https://doi.org/10.1016/j.measurement.2021.109885>
- Bandt, C., & Pompe, B. (2002). Permutation entropy: A natural complexity measure for time series. *Physical Review Letters*, 88(17), 174102. <https://doi.org/10.1103/PhysRevLett.88.174102>
- Bayram, S., Kaplan, K., Kuncan, M., & Ertunç, H. M. (2014). The effect of bearings faults to coefficients obtained by using wavelet transform. In *2014 22nd Signal Processing and Communications Applications Conference (SIU)* (pp. 991-994). IEEE. <https://doi.org/10.1109/SIU.2014.6830398>
- Cao, Y., Ding, Y., Jia, M., & Tian, R. (2021). A novel temporal convolutional network with residual self-attention mechanism for remaining useful life prediction of rolling bearings. *Reliability Engineering & System Safety*, 215, 107813. <https://doi.org/10.1016/j.ress.2021.107813>
- Chen, Y., Peng, G., Zhu, Z., & Li, S. (2020). A novel deep learning method based on attention mechanism for bearing remaining useful life prediction. *Applied Soft Computing*, 86, 105919. <https://doi.org/10.1016/j.asoc.2019.105919>
- Chen, Z., Guo, L., Gao, H., Yu, Y., Wu, W., You, Z., & Dong, X. (2021). A fault pulse extraction and feature enhancement method for bearing fault diagnosis. *Measurement*, 182, 109718. <https://doi.org/10.1016/j.measurement.2021.109718>

- Cheng, H., Kong, X., Chen, G., Wang, Q., & Wang, R. (2021). Transferable convolutional neural network based remaining useful life prediction of bearing under multiple failure behaviors. *Measurement*, 168, 108286. <https://doi.org/10.1016/j.measurement.2020.108286>
- Cuesta-Frau, D. (2019). Slope entropy: A new time series complexity estimator based on both symbolic patterns and amplitude information. *Entropy*, 21(12), 1167. <https://doi.org/10.3390/e21121167>
- Cui, L., Xiao, Y., Liu, D., & Han, H. (2024). Digital twin-driven graph domain adaptation neural network for remaining useful life prediction of rolling bearing. *Reliability Engineering & System Safety*, 245, 109991. <https://doi.org/10.1016/j.ress.2023.109991>
- Deveci, B. U., Celtikoglu, M., Alp, T., Albayrak, O., Unal, P., & Kirci, P. (2021, August). A comparison of deep transfer learning methods on bearing fault detection. In *2021 8th International Conference on Future Internet of Things and Cloud (FiCloud)* (pp. 285-292). IEEE. <https://doi.org/10.1109/FiCloud49777.2021.00048>
- Dong, S., Xiao, J., Hu, X., Fang, N., Liu, L., & Yao, J. (2023). Deep transfer learning based on Bi-LSTM and attention for remaining useful life prediction of rolling bearing. *Reliability Engineering & System Safety*, 230, 108914. <https://doi.org/10.1016/j.ress.2023.108914>
- Du, X., Jia, W., Yu, P., Shi, Y., & Cheng, S. (2022). A remaining useful life prediction method based on time–frequency images of the mechanical vibration signals. *Measurement*, 202, 111782. <https://doi.org/10.1016/j.measurement.2022.111782>
- Gao, L., Wang, J., & Chen, L. (2013). Event-related desynchronization and synchronization quantification in motor-related EEG by Kolmogorov entropy. *Journal of Neural Engineering*, 10(3), 036023. <https://doi.org/10.1088/1741-2560/10/3/036023>
- Grassberger, P., & Procaccia, I. (1983). Estimation of the Kolmogorov entropy from a chaotic signal. *Physical Review A*, 28(4), 2591-2593. <https://doi.org/10.1103/PhysRevA.28.2591>
- Han, T., Zhang, L., Yin, Z., & Tan, A. C. (2021). Rolling bearing fault diagnosis with combined convolutional neural networks and support vector machine. *Measurement*, 177, 109022. <https://doi.org/10.1016/j.measurement.2021.109022>
- Harris, T. A., ve Kotzalas, M. N. (2006). *Essential Concepts of Bearing Technology* (5th ed.). CRC Press. <https://doi.org/10.1201/9781420006582>
- He, Z., Shen, C., Chen, B., Shi, J., Huang, W., Zhu, Z., & Wang, D. (2024). A new feature boosting based continual learning method for bearing fault diagnosis with incremental fault types. *Advanced Engineering Informatics*, 61, 102469. <https://doi.org/10.1016/j.aei.2023.102469>

- Hoang, D. T., & Kang, H. J. (2019). Rolling element bearing fault diagnosis using convolutional neural network and vibration image. *Cognitive Systems Research*, 53, 42-50. <https://doi.org/10.1016/j.cogsys.2018.03.002>
- Hou, Y., Wang, J., Chen, Z., Ma, J., & Li, T. (2023). Diagnosisformer: An efficient rolling bearing fault diagnosis method based on improved Transformer. *Engineering Applications of Artificial Intelligence*, 124, 106507. <https://doi.org/10.1016/j.engappai.2023.106507>
- Hou, Y., Zhou, C., Tian, C., Wang, D., He, W., Huang, W., ... & Wu, D. (2022). Acoustic feature enhancement in rolling bearing fault diagnosis using sparsity-oriented multipoint optimal minimum entropy deconvolution adjusted method. *Applied Acoustics*, 201, 109105. <https://doi.org/10.1016/j.apacoust.2022.109105>
- Hsu, C. F., Wei, S. Y., Huang, H. P., Hsu, L., Chi, S., & Peng, C. K. (2017). Entropy of entropy: Measurement of dynamical complexity for biological systems. *Entropy*, 19(10), 550. <https://doi.org/10.3390/e19100550>
- Hu, T., Guo, Y., Gu, L., Zhou, Y., Zhang, Z., & Zhou, Z. (2022). Remaining useful life prediction of bearings under different working conditions using a deep feature disentanglement based transfer learning method. *Reliability Engineering & System Safety*, 219, 108265. <https://doi.org/10.1016/j.res.2021.108265>
- Huang, C. G., Huang, H. Z., & Li, Y. F. (2019). A bidirectional LSTM prognostics method under multiple operational conditions. *IEEE Transactions on Industrial Electronics*, 66(11), 8792-8802. <https://doi.org/10.1109/TIE.2019.2891463>
- Huang, C. G., Huang, H. Z., Li, Y. F., & Peng, W. (2021). A novel deep convolutional neural network-bootstrap integrated method for RUL prediction of rolling bearing. *Journal of Manufacturing Systems*, 61, 757-772. <https://doi.org/10.1016/j.jmsy.2021.03.012>
- Huang, G. B., Zhu, Q. Y., & Siew, C. K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1-3), 489-501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Huang, M., Yin, J., Yan, S., & Xue, P. (2023). A fault diagnosis method of bearings based on deep transfer learning. *Simulation Modelling Practice and Theory*, 122, 102659. <https://doi.org/10.1016/j.simpat.2022.102659>
- Huo, Z., Zhang, Y., Shu, L., & Liao, X. (2019). Edge permutation entropy: An improved entropy measure for time-series analysis. In *IECON 2019-45th Annual Conference of the IEEE Industrial Electronics Society* (Vol. 1, pp. 5998-6003). IEEE. <https://doi.org/10.1109/IECON.2019.8927449>
- Inouye, T., Shinosaki, K., Sakamoto, H., Toi, S., Ukai, S., Iyama, A., ... & Hirano, M. (1991). Quantification of EEG irregularity by use of the entropy of the power spectrum. *Electroencephalography and Clinical Neurophysiology*, 79(3), 204-210. [https://doi.org/10.1016/0013-4694\(91\)90138-T](https://doi.org/10.1016/0013-4694(91)90138-T)

- Jia, L., Chow, T. W., & Yuan, Y. (2023). GTFE-Net: A gramian time frequency enhancement CNN for bearing fault diagnosis. *Engineering Applications of Artificial Intelligence*, 119, 105794. <https://doi.org/10.1016/j.engappai.2022.105794>
- Jin, Z., Xiao, Y., He, D., Wei, Z., Sun, Y., & Yang, W. (2023). Fault diagnosis of bearing based on refined piecewise composite multivariate multiscale fuzzy entropy. *Digital Signal Processing*, 133, 103884. <https://doi.org/10.1016/j.dsp.2023.103884>
- Kaplan, K., Kuncan, M., & Ertunç, H. M. (2015). Prediction of bearing fault size by using model of adaptive neuro-fuzzy inference system. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 1925-1928). IEEE. <https://doi.org/10.1109/SIU.2015.7130237>
- Kaya, Y., & Ertuğrul, Ö. F. (2016). A novel feature extraction approach in SMS spam filtering for mobile communication: One-dimensional ternary patterns. *Security and Communication Networks*, 9(17), 4680-4690. <https://doi.org/10.1002/sec.1660>
- Kaya, Y., Kuncan, F., & Ertunç, H. M. (2022). A new automatic bearing fault size diagnosis using time-frequency images of CWT and deep transfer learning methods. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(5), 1851-1867. <https://doi.org/10.55730/1300-0632.3909>
- Kaya, Y., Kuncan, F., & Ertunç, H. M. (2022). A new automatic bearing fault size diagnosis using time-frequency images of CWT and deep transfer learning methods. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(5), 1851-1867. <https://doi.org/10.55730/1300-0632.3909>
- Kaya, Y., Kuncan, M., Kaplan, K., Minaz, M. R., & Ertunç, H. M. (2021). A new feature extraction approach based on one dimensional gray level co-occurrence matrices for bearing fault classification. *Journal of Experimental & Theoretical Artificial Intelligence*, 33(1), 161-178. <https://doi.org/10.1080/0952813X.2020.1735530>
- Kaya, Y., Uyar, M., Tekin, R., & Yıldırım, S. (2014). 1D-local binary pattern based feature extraction for classification of epileptic EEG signals. *Applied Mathematics and Computation*, 243, 209-219. <https://doi.org/10.1016/j.amc.2014.05.128>
- Kumar, A., Parkash, C., Zhou, Y., Kundu, P., Xiang, J., Tang, H., ... & Chauhan, S. (2024). Entropy-based domain adaptation strategy for predicting remaining useful life of rolling element bearing. *Engineering Applications of Artificial Intelligence*, 133, 108575. <https://doi.org/10.1016/j.engappai.2023.108575>
- Kuncan, M. (2020). An intelligent approach for bearing fault diagnosis: combination of 1D-LBP and GRA. *IEEE Access*, 8, 137517-137529. <https://doi.org/10.1109/ACCESS.2020.3011980>
- Kuncan, M., Kaplan, K., Minaz, M. R., Kaya, Y., & Ertunç, H. M. (2020). A novel feature extraction method for bearing fault classification with one dimensional ternary patterns. *ISA Transactions*, 100, 346-357. <https://doi.org/10.1016/j.isatra.2019.11.006>

- Lee, J., Sun, Z., Tan, T. B., Mendez, J., Flores-Cerrillo, J., Wang, J., & He, Q. P. (2022). Remaining useful life estimation for ball bearings using feature engineering and extreme learning machine. *IFAC-PapersOnLine*, 55(7), 198-203. <https://doi.org/10.1016/j.ifacol.2022.07.444>
- Li, P., Liu, C., Li, K., Zheng, D., Liu, C., & Hou, Y. (2015). Assessing the complexity of short-term heartbeat interval series by distribution entropy. *Medical & Biological Engineering & Computing*, 53, 77-87. <https://doi.org/10.1007/s11517-014-1216-0>
- Li, Q., Yan, C., Chen, G., Wang, H., Li, H., & Wu, L. (2022). Remaining useful life prediction of rolling bearings based on risk assessment and degradation state coefficient. *ISA transactions*, 129, 413-428. <https://doi.org/10.1016/j.isatra.2022.01.031>
- Li, X., Zhang, W., & Ding, Q. (2019). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering & System Safety*, 182, 208-218. <https://doi.org/10.1016/j.ress.2018.11.011>
- Li, Y., Yang, Y., Li, G., Xu, M., & Huang, W. (2017). A fault diagnosis scheme for planetary gearboxes using modified multi-scale symbolic dynamic entropy and mRMR feature selection. *Mechanical Systems and Signal Processing*, 91, 295-312. <https://doi.org/10.1016/j.ymssp.2016.12.040>
- Liang, N. Y., Saratchandran, P., Huang, G. B., & Sundararajan, N. (2006). Classification of mental tasks from EEG signals using extreme learning machine. *International Journal of Neural Systems*, 16(01), 29-38. <https://doi.org/10.1142/S0129065706000482>
- Liang, Q. Z., Guo, X. M., Zhang, W. Y., Dai, W. D., & Zhu, X. H. (2015). Identification of heart sounds with arrhythmia based on recurrence quantification analysis and Kolmogorov entropy. *Journal of Medical and Biological Engineering*, 35, 209-217. <https://doi.org/10.1007/s40846-015-0022-y>
- Liu, A., Yang, Z., Li, H., Wang, C., & Liu, X. (2022). Intelligent diagnosis of rolling element bearing based on refined composite multiscale reverse dispersion entropy and random forest. *Sensors*, 22(5), 2046. <https://doi.org/10.3390/s22052046>
- Liu, L., Song, X., Chen, K., Hou, B., Chai, X., & Ning, H. (2021). An enhanced encoder-decoder framework for bearing remaining useful life prediction. *Measurement*, 170, 108753. <https://doi.org/10.1016/j.measurement.2020.108753>
- Liu, S., & Fan, L. (2022). An adaptive prediction approach for rolling bearing remaining useful life based on multistage model with three-source variability. *Reliability Engineering & System Safety*, 218, 108182. <https://doi.org/10.1016/j.ress.2022.108182>
- Liu, S., Xie, J., Shen, C., Shang, X., Wang, D., & Zhu, Z. (2020). Bearing fault diagnosis based on improved convolutional deep belief network. *Applied Sciences*, 10(18), 6359. <https://doi.org/10.3390/app10186359>

- Liu, X., Wang, X., Zhou, X., & Jiang, A. (2018). Appropriate use of the increment entropy for electrophysiological time series. *Computers in Biology and Medicine*, 95, 13-23. <https://doi.org/10.1016/j.compbiomed.2018.01.009>
- Malekipirbazari, M., Aksakalli, V., Shafqat, W., & Eberhard, A. (2021). Performance comparison of feature selection and extraction methods with random instance selection. *Expert Systems with Applications*, 179, 115072. <https://doi.org/10.1016/j.eswa.2021.115072>
- Manis, G., Aktaruzzaman, M. D., & Sassi, R. (2017). Bubble entropy: An entropy almost free of parameters. *IEEE Transactions on Biomedical Engineering*, 64(11), 2711-2718. <https://doi.org/10.1109/TBME.2017.2664105>
- Meng, Z., Liu, J., Liu, J., Li, J., Cao, L., Fan, F., & Yu, S. (2023). An improved variational mode decomposition method based on spectrum reconstruction and segmentation and its application in rolling bearing fault diagnosis. *Digital Signal Processing*, 141, 104161. <https://doi.org/10.1016/j.dsp.2023.104161>
- Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-Morello, B., Zerhouni, N., & Varnier, C. (2012, June). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. In *IEEE International Conference on Prognostics and Health Management, PHM'12*. (pp. 1-8). IEEE Catalog Number: CPF12PHM-CDR.
- Pan, Z., Meng, Z., Chen, Z., Gao, W., & Shi, Y. (2020). A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. *Mechanical Systems and Signal Processing*, 144, 106899. <https://doi.org/10.1016/j.ymssp.2020.106899>
- Pei, X., Zheng, X., & Wu, J. (2021). Intelligent bearing fault diagnosis based on Teager energy operator demodulation and multiscale compressed sensing deep autoencoder. *Measurement*, 179, 109452. <https://doi.org/10.1016/j.measurement.2021.109452>
- Piltan, F., & Kim, J. M. (2023). Bearing fault diagnosis using a hybrid fuzzy V-structure fault estimator scheme. *Sensors*, 23(2), 1021. <https://doi.org/10.3390/s23021021>
- Pincus, S. M. (1991). Approximate entropy as a measure of system complexity. *Proceedings of the National Academy of Sciences*, 88(6), 2297-2301. <https://doi.org/10.1073/pnas.88.6.2297>
- Porta, A., Baselli, G., Liberati, D., Montano, N., Cogliati, C., Gneccchi-Ruscione, T., ... & Cerutti, S. (1998). Measuring regularity by means of a corrected conditional entropy in sympathetic outflow. *Biological Cybernetics*, 78, 71-78. <https://doi.org/10.1007/s004220050414>
- Randall, R. B., & Antoni, J. (2011). Rolling element bearing diagnostics—A tutorial. *Mechanical Systems and Signal Processing*, 25(2), 485-520. <https://doi.org/10.1016/j.ymssp.2010.07.017>

- Rastegari, A. (2017). *Condition based maintenance in the manufacturing industry: from strategy to implementation*. [Doctoral dissertation]. Mälardalen University.
- Rathore, M. S., & Harsha, S. P. (2022). An attention-based stacked BiLSTM framework for predicting remaining useful life of rolling bearings. *Applied Soft Computing*, 131, 109765. <https://doi.org/10.1016/j.asoc.2022.109765>
- Rathore, M. S., & Harsha, S. P. (2022). Roller bearing failure analysis using Gaussian mixture models and convolutional neural networks. *Journal of Failure Analysis and Prevention*, 22(5), 1853-1871. <https://doi.org/10.1007/s11668-022-01469-8>
- Ravikumar, K. N., Yadav, A., Kumar, H., Gangadharan, K. V., & Narasimhadhan, A. V. (2021). Gearbox fault diagnosis based on Multi-Scale deep residual learning and stacked LSTM model. *Measurement*, 186, 110099. <https://doi.org/10.1016/j.measurement.2021.110099>
- Richman, J. S., & Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology-Heart and Circulatory Physiology*, 278(6), H2039-H2049. <https://doi.org/10.1152/ajpheart.2000.278.6.H2039>
- Rohila, A., & Sharma, A. (2019). Phase entropy: A new complexity measure for heart rate variability. *Physiological Measurement*, 40(10), 105006. <https://doi.org/10.1088/1361-6579/ab499e>
- Rostaghi, M., & Azami, H. (2016). Dispersion entropy: A measure for time-series analysis. *IEEE Signal Processing Letters*, 23(5), 610-614. <https://doi.org/10.1109/LSP.2016.2542881>
- Shan, S., Liu, J., Wu, S., Shao, Y., & Li, H. (2023). A motor bearing fault voiceprint recognition method based on Mel-CNN model. *Measurement*, 207, 112408. <https://doi.org/10.1016/j.measurement.2023.112408>
- Sun, Y., & Wang, Z. (2024). Remaining useful life prediction of rolling bearing via composite multiscale permutation entropy and Elman neural network. *Engineering Applications of Artificial Intelligence*, 135, 108852. <https://doi.org/10.1016/j.engappai.2023.108852>
- Sun, Z., Machlev, R., Wang, Q., Belikov, J., Levron, Y., & Baimel, D. (2023). A public data-set for synchronous motor electrical faults diagnosis with CNN and LSTM reference classifiers. *Energy and AI*, 14, 100274. <https://doi.org/10.1016/j.egyai.2023.100274>
- Suresh, S., Saraswathi, S., & Sundararajan, N. (2010). Performance enhancement of extreme learning machine for multi-category sparse data classification problems. *Engineering Applications of Artificial Intelligence*, 23(7), 1149-1157. <https://doi.org/10.1016/j.engappai.2010.06.009>

- Tong, J., Tang, S., Wu, Y., Pan, H., & Zheng, J. (2023). A fault diagnosis method of rolling bearing based on improved deep residual shrinkage networks. *Measurement*, 206, 112282. <https://doi.org/10.1016/j.measurement.2023.112282>
- Urbanowicz, R. J., Meeker, M., La Cava, W., Olson, R. S., & Moore, J. H. (2018). Relief-based feature selection: Introduction and review. *Journal of Biomedical Informatics*, 85, 189-203. <https://doi.org/10.1016/j.jbi.2018.07.014>
- Vos, K., Peng, Z., Jenkins, C., Shahriar, M. R., Borghesani, P., & Wang, W. (2022). Vibration-based anomaly detection using LSTM/SVM approaches. *Mechanical Systems and Signal Processing*, 169, 108752. <https://doi.org/10.1016/j.ymssp.2022.108752>
- Wan, L., Li, Y., Chen, K., Gong, K., & Li, C. (2022). A novel deep convolution multi-adversarial domain adaptation model for rolling bearing fault diagnosis. *Measurement*, 191, 110752. <https://doi.org/10.1016/j.measurement.2022.110752>
- Wang, B., Lei, Y., Li, N., & Yan, T. (2019). Deep separable convolutional network for remaining useful life prediction of machinery. *Mechanical Systems and Signal Processing*, 134, 106330. <https://doi.org/10.1016/j.ymssp.2019.106330>
- Wang, H., Wang, D., Liu, H., & Tang, G. (2022). A predictive sliding local outlier correction method with adaptive state change rate determining for bearing remaining useful life estimation. *Reliability Engineering & System Safety*, 225, 108601. <https://doi.org/10.1016/j.ress.2022.108601>
- Wang, J., Zhang, Y., Zhang, F., Li, W., Lv, S., Jiang, M., & Jia, L. (2021). Accuracy-improved bearing fault diagnosis method based on AVMD theory and AWPSO-ELM model. *Measurement*, 181, 109666. <https://doi.org/10.1016/j.measurement.2021.109666>
- Wang, P., Xiong, H., & He, H. (2023). Bearing fault diagnosis under various conditions using an incremental learning-based multi-task shared classifier. *Knowledge-Based Systems*, 266, 110395. <https://doi.org/10.1016/j.knosys.2023.110395>
- Wang, Q., Xu, K., Kong, X., & Huai, T. (2021). A linear mapping method for predicting accurately the RUL of rolling bearing. *Measurement*, 176, 109127. <https://doi.org/10.1016/j.measurement.2021.109127>
- Wang, X., Mao, D., & Li, X. (2021). Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network. *Measurement*, 173, 108518. <https://doi.org/10.1016/j.measurement.2021.108518>
- Wu, C., & Zheng, S. (2024). Fault Diagnosis Method of Rolling Bearing Based on MSCNN-LSTM. *Computers, Materials & Continua*, 79(3). <https://doi.org/10.32604/cmc.2024.022075>
- Wu, Y., Liu, L., & Qian, S. (2023). A small sample bearing fault diagnosis method based on variational mode decomposition, autocorrelation function, and convolutional

- neural network. *The International Journal of Advanced Manufacturing Technology*, 124(11-12), 3887-3898. <https://doi.org/10.1007/s00170-023-12020-4>
- Xiang, J., Li, C., Li, H., Cao, R., Wang, B., Han, X., & Chen, J. (2015). The detection of epileptic seizure signals based on fuzzy entropy. *Journal of Neuroscience Methods*, 243, 18-25. <https://doi.org/10.1016/j.jneumeth.2015.01.015>
- Xie, H. B., He, W. X., & Liu, H. (2008). Measuring time series regularity using nonlinear similarity-based sample entropy. *Physics Letters A*, 372(48), 7140-7146. <https://doi.org/10.1016/j.physleta.2008.10.049>
- Xu, K., Kong, X., Wang, Q., Yang, S., Huang, N., & Wang, J. (2022). A bearing fault diagnosis method without fault data in new working condition combined dynamic model with deep learning. *Advanced Engineering Informatics*, 54, 101795. <https://doi.org/10.1016/j.aei.2022.101795>
- Yan, C., Li, P., Liu, C., Wang, X., Yin, C., & Yao, L. (2019). Novel gridded descriptors of Poincaré plot for analyzing heartbeat interval time-series. *Computers in Biology and Medicine*, 109, 280-289. <https://doi.org/10.1016/j.combiomed.2019.04.015>
- Yan, M., Wang, X., Wang, B., Chang, M., & Muhammad, I. (2020). Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA transactions*, 98, 471-482. <https://doi.org/10.1016/j.isatra.2020.01.018>
- Yang, J., Choudhary, G. I., Rahardja, S., & Fränti, P. (2020). Classification of interbeat interval time-series using attention entropy. *IEEE Transactions on Affective Computing*, 14(1), 321-330. <https://doi.org/10.1109/TAFFC.2020.3031004>
- Yao, P., Wang, J., Zhang, F., Li, W., Lv, S., Jiang, M., & Jia, L. (2022). Intelligent rolling bearing imbalanced fault diagnosis based on Mel-Frequency Cepstrum Coefficient and Convolutional Neural Networks. *Measurement*, 205, 112143. <https://doi.org/10.1016/j.measurement.2022.112143>
- Ye, M., Yan, X., Chen, N., & Jia, M. (2023). Intelligent fault diagnosis of rolling bearing using variational mode extraction and improved one-dimensional convolutional neural network. *Applied Acoustics*, 202, 109143. <https://doi.org/10.1016/j.apacoust.2023.109143>
- Yoo, Y., & Baek, J. G. (2018). A novel image feature for the remaining useful lifetime prediction of bearings based on continuous wavelet transform and convolutional neural network. *Applied Sciences*, 8(7), 1102. <https://doi.org/10.3390/app8071102>
- Yoo, Y., Jo, H., & Ban, S. W. (2023). Lite and efficient deep learning model for bearing fault diagnosis using the CWRU dataset. *Sensors*, 23(6), 3157. <https://doi.org/10.3390/s23063157>
- Yu, Z., Zhang, C., & Deng, C. (2023). An improved GNN using dynamic graph embedding mechanism: A novel end-to-end framework for rolling bearing fault diagnosis under variable working conditions. *Mechanical Systems and Signal Processing*, 200, 110534. <https://doi.org/10.1016/j.ymssp.2022.110534>

- Zhang, T., Liu, S., Wei, Y., & Zhang, H. (2021). A novel feature adaptive extraction method based on deep learning for bearing fault diagnosis. *Measurement*, 185, 110030. <https://doi.org/10.1016/j.measurement.2021.110030>
- Zhuang, J., Jia, M., & Zhao, X. (2022). An adversarial transfer network with supervised metric for remaining useful life prediction of rolling bearing under multiple working conditions. *Reliability Engineering & System Safety*, 108599. <https://doi.org/10.1016/j.ress.2022.108599>
- Zou, Y., Li, Z., Liu, Y., Zhao, S., Liu, Y., & Ding, G. (2022). A method for predicting the remaining useful life of rolling bearings under different working conditions based on multi-domain adversarial networks. *Measurement*, 188, 110393. <https://doi.org/10.1016/j.measurement.2022.110393>

